



“UNIVERSIDAD NACIONAL “PEDRO RUIZ GALLO”

FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS

ESCUELA PROFESIONAL DE ESTADÍSTICA



**“MODELO DE BOX Y JENKINS Y REDES NEURONALES PARA
PRONOSTICAR EL PRECIO DEL DÓLAR DEL SISTEMA BANCARIO
EN MONEDA NACIONAL AÑO 2015”.**

TESIS

PRESENTADA POR:

BACH. FLOR MARIBEL VÁSQUEZ MEJÍA

**PARA OPTAR EL TÍTULO PROFESIONAL DE
LICENCIADO EN ESTADÍSTICA.**

Lambayeque – Perú

2017

“UNIVERSIDAD NACIONAL “PEDRO RUIZ GALLO”

FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS

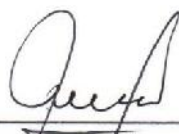
ESCUELA PROFESIONAL DE ESTADÍSTICA

**TESIS PARA OPTAR EL TÍTULO PROFESIONAL EN LICENCIADO EN
ESTADÍSTICA**

**“MODELO DE BOX Y JENKINS Y REDES NEURONALES PARA
PRONOSTICAR EL PRECIO DEL DÓLAR DEL SISTEMA BANCARIO
EN MONEDA NACIONAL AÑO 2015”.**



**M.SC. ALFONSO, TESEN ARROYO
ASESOR**

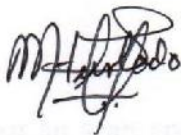


**Bach. FLOR MARIBEL, VÁSQUEZ MEJÍA
TESISTA**

Lambayeque – Perú

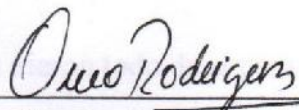
2017

Tesis aprobado por el jurado:



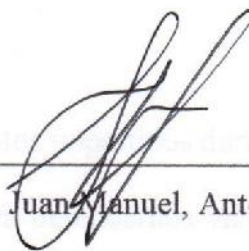
M.Sc. Manuel Francisco, Hurtado Sánchez

Presidente



M.Sc. Wilver Omero, Rodríguez López

Secretario



M.Sc. Juan Manuel, Antón Pérez

Vocal

AGRADECIMIENTO

A mi Asesor

M.Sc. Alfonso Tesén Arroyo, por su gran apoyo, motivación y paciencia, para la elaboración de esta tesis.

A todos mis Maestros,

Que cada día dieron todo de sí para obtener conocimientos impartidos durante toda su experiencia laboral, gracias a ellos podemos ahora defendernos en nuestros centros de trabajo.

DEDICATORIA

A Dios,

Por haberme permitido concluir la universidad, darme vida, salud y estar conmigo en las buenas y en las malas, en las noches más frías de viajes más largos de mi vida para lograr mis objetivos propuestos para un futuro mejor.

A mis padres y hermanos,

Por ser el pilar fundamental en todo lo que soy, en toda mi educación, tanto académica, económica y cultural, *GLORIA Y NESTOR* gracias por darme una carrera para mi futuro, por todo esto quedaré eternamente agradecida a ustedes.

¡Gracias!

PRESENTACIÓN

El presente trabajo de investigación se hace con la finalidad de compartir algunos temas e ideas que han surgido durante los últimos años, para resolver problemas relacionados al mundo real (reconocimiento de formas, toma de decisiones, pronósticos etc.) esto definitivamente facilita a la investigación de estudio la cual es la clave para garantizar un buen resultado.

De entre estas metodologías, de Box y Jenkins y Redes Neuronales Artificiales son las que actualmente están causando mayor impacto, debido a su extraordinaria aplicabilidad práctica por el buen resultado estadístico y análisis de datos que sirven para clasificar patrones y la estimación de variables.

La presente tesis, el objetivo es determinar un modelo de Box y Jenkins y redes neuronales que permita pronosticar el precio del dólar a moneda nacional, ya obtenidos los resultados de los pronósticos estadísticos con las metodologías en estudio se puede garantizar un resultado concreto y eficaz, para proponer la información a las empresas e instituciones financieras publicas y privadas, que requieren para utilizar con éxito la metodología más adecuada y fácil de utilizar que permita llegar a pronósticos que solicitan en su debido momento.

RESUMEN

La presente investigación tuvo como objetivo Estimar un modelo mediante la metodología de Box y Jenkins y Redes Neuronales Artificiales que permita pronosticar el precio del dólar del Sistema Bancario en moneda nacional año 2015.

La investigación es de tipo descriptiva, predictiva-longitudinal. Los datos para el pronóstico del precio de la compra y venta del dólar se obtuvieron de la página web del BCRP, www.bcrp.go.pe. Contando con un periodo de 11 años desde 2004 hasta 2014.

Las nociones básicas de análisis de Series de Tiempo y Redes Neuronales Artificiales se exponen brevemente en el desarrollo de la tesis.

El modelo para el pronóstico que se obtuvo mediante la metodología de Box y Jenkins es un ARIMA (2, 2,3), con un RMSE igual 0.983 para la compra con un MAE de 0.008 y la venta un ARIMA (3, 1,2) con un RMSE de 0.982y con un MAE de 0.008 indicando un buen coeficiente.

Por lo tanto, el modelo de Redes Neuronales Artificiales tiene una estructura de (12:1:5:1) con RMSE 0.042 para la compra y para la venta con estructura de (12:1:6:1) con RMSE 0.038.

PALABRAS CLAVES: Box y Jenkins, ARIMA y Redes Neuronales Artificiales (RNA), Pronósticos.

ABSTRACT

The objective of this research was to estimate a model using the Box and Jenkins methodology and Artificial Neural Networks that allows predicting the price of the dollar of the Banking System in national currency year 2015.

The investigation is of a descriptive, predictive-longitudinal type. The data for the forecast of the price of the purchase and sale of the dollar were obtained from the BCRP's website, www.bcrp.go.pe. Counting on a period of 11 years from 2004 to 2014.

The basic notions of Analysis of Time Series and Artificial Neural Networks are briefly explained in the development of the thesis.

The model for the forecast obtained by the Box and Jenkins methodology is an ARIMA (2, 2.3) with an error of 0.008 and with $R_2 = 0.983$ for the purchase and sale of an ARIMA (3, 1.2) with an error of 0.008 and an R_2 of 0.982 indicating a good coefficient.

Therefore, the Artificial Neural Networks model has a structure of (12: 1: 5: 1) with RMSE 0.042 for purchase and for sale with structure of (12: 1: 6: 1) with RMSE 0.038.

KEY WORDS: Box and Jenkins, ARIMA and Artificial Neural Networks (ANN), Forecasts.

ÍNDICE GENERAL

CAPÍTULO I. INTRODUCCIÓN	1
1.1. ASPECTOS DE LA PROBLEMÁTICA	3
1.1.1. Formulación del problema científico	3
1.1.2. Objetivos de estudio	3
1.1.3. Antecedentes de la investigación	3
1.2. MARCO TEÓRICO	7
1.2.1. Series de Tiempo y Metodología de box y Jenkins	7
1.2.1.1. Nociones básicas de series de tiempo	7
1.2.2.2. Clasificación de las series de tiempo	7
1.2.2.3. Componentes de una serie de tiempo	9
1.2.2. Pronósticos de Series de Tiempo	10
1.2.3. Metodología de Box y Jenkins	12
1.2.4. Modelos ARIMA	11
1.2.5. Estrategia de Modelización ARIMA	15
1.2.6. Redes Neuronales Artificiales	17
1.2.7. Modelo de una Red Neuronal Artificial	18
1.2.8. Elementos de una neurona	18
1.2.9. Arquitectura de Redes Neuronales Artificiales	19
1.2.10. Capas de las Redes Neuronales Artificiales	19
1.2.11. Funciones de las Redes Neuronales Artificiales	21
1.2.12. Clasificación de las Redes Neuronales Artificiales	23
1.2.13. Características de las Redes Neuronales Artificiales	25
1.2.14. Tipo de cambio	26
1.2.15. El dólar	29

CAPÍTULO II. MATERIALES Y METODOS	30
2.1. Tipo de investigación	30
2.2. El diseño de la investigación:	30
2.3. Variables	30
2.4. Población	30
2.5. Muestra	30
2.6. Metodos, Técnica e Instrumento de Recolección de Datos	31
2.7. Procesamiento Estadístico	31
CAPÍTULO III. RESULTADOS Y DISCUSION	36
3.1. Estadísticos descriptivos de la compra y venta del dólar del sistema registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	36
3.2. Resultados tipo de cambio de la compra del dólar mediante la metodología de Box y Jenkins.	37
Paso N° 1 Grafica de la serie original	37
Paso N° 2 Correlograma total de la serie original	38
Paso N° 3 Análisis de la estacionariedad	39
Paso N° 4 Estimación del modelo	42
Paso N° 5 Validación del modelo	44
Paso N° 6 Pronóstico del Modelo ARIMA	48
3.3. Resultados tipo de cambio de la venta del dólar mediante la metodología de Box y Jenkins.	
Paso N° 1 Grafica de la serie original	50
Paso N° 2 Correlograma total de la serie original	51
Paso N° 3 Análisis de estacionariedad.	52
Paso N° 4 Estimación del modelo –Venta	55

Paso N° 5 Validación del Modelo Arima-Venta	57
Paso N° 6 Pronósticos de los Modelos Arima -Venta	61
3.4. Resultados tipo de cambio de la compra del dólar mediante redes neuronales artificiales.	63
3.5. Resultados tipo de cambio de la venta del dólar mediante redes neuronales artificiales.	69
3.5.1. Pronóstico de Redes Neuronales Artificiales Compra y Venta dólar	75
3.6 Comparación de los modelos de RNA y Box y Jenkins	76
CAPÍTULO IV. CONCLUSIONES SUGERENCIAS	77
REFERENCIAS BIBLIOGRAFICAS	80
ANEXOS	83
APENDICE	114

ÍNDICE DE TABLAS

Tabla N° 01	Comportamiento de la función autocorrelación simple (ACF) y la función de autocorrelación parcial (ACFP).	14
Tabla N° 02	Estadísticos descriptivos de la compra y venta del dólar del Sistema Bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	36
Tabla N° 03	Prueba de homogeneidad de varianzas de la serie diferenciada en 2 periodos del Logaritmo Natural de la compra del dólar del sistema bancario, periodo enero 2004 a diciembre 2014.	41
Tabla N° 04	ANOVA para la diferencia en 2 periodos del Logaritmo Natural de la compra del dólar en el sistema bancario, periodo enero 2004 a diciembre 2014.	41
Tabla N° 05	Parámetros de los modelo ARIMA, para la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 – diciembre 2014.	42
	Significancia de los parámetros de los modelos para las series	43
Tabla N° 06	compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.	
Tabla N° 07	Parámetros del modelo ARIMA(2,2,3) para la diferencia en 2 periodos del logaritmo natural en la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.	44
Tabla N°08	Prueba de Kolmogorov-Smirnov para los residuos del modelo ARIMA (2, 2, 3)	45

Tabla N°09	Prueba de homogeneidad de varianzas para los residuos del modelo ARIMA (2,2,3)	46
Tabla N°10	ANOVA para los residuos del modelo ARIMA (2, 2, 3)	46
Tabla N° 11	Pronostico de la compra del dólar periodo enero 2015 a diciembre 2015.	48
Tabla N° 12	Prueba de homogeneidad de varianzas de la serie diferenciada de la Tran-Logaritmo Natural de la venta del dólar del sistema bancario, periodo enero 2004 a diciembre 2014.	54
Tabla N° 13	ANOVA para la diferencia del Logaritmo Natural de la venta del dólar del sistema bancario, periodo enero 2004 a diciembre 2014.	54
Tabla N° 14	Parámetros de los modelos ARIMA, para la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 – diciembre 2014.	55
Tabla N° 15	Significancia de los parámetros de los modelos para la serie venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.	56
Tabla N° 16	Parámetros del modelo ARIMA (3,1,2) para la diferencia en un periodos del logaritmo natural en la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.	57
Tabla N° 17	Prueba de Kolmogorov-Smirnov para los residuos del modelo ARIMA (3, 1, 2)	58
Tabla N° 18	Prueba de homogeneidad de varianzas para los residuos del modelo ARIMA (3,1,2).	59

Tabla N° 19	ANOVA para los residuos del modelo ARIMA (3,1, 2).	59
Tabla N° 20	Pronósticos de la compra y venta del dólar, registrados por el BCRP, para el periodo enero 2015 a diciembre 2015.	60
Tabla N° 21	Modelos de redes neuronales Perceptrón Multicapa (MPL) para Pronosticar el precio del dólar del sistema bancario en moneda nacional registrados por el BCRP, periodo enero 2004 a diciembre 2014.	63
Tabla N° 22	Procesamiento de los casos de Redes neuronales Artificiales de la compra del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	64
Tabla N°23	Información sobre la red neuronal de la compra del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014	66
Tabla N°24	Resumen del modelo de la red neuronal –MLP aplicado a la compra del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	67
Tabla N°25	Estimación de los parámetros del modelo de la red neuronal –MPL, aplicado a la compra del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014	68
Tabla N° 26	Modelos de redes neuronales Perceptrón Multicapa (MPL) para Pronosticar el precio de venta del dólar del sistema bancario en	69

moneda nacional registrados por el BCRP, periodo enero 2004 a diciembre 2014.

	Procesamiento de los casos de Redes Neuronales Artificiales	70
Tabla N°27	de la Venta dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	
Tabla N° 28	Información sobre la red neuronal de la venta del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	72
Tabla N° 29	Resumen del modelo de la red neuronal –MLP aplicado a la venta del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	73
Tabla N° 30	Estimación de los parámetros del modelo de la red neuronal – MPL, aplicado a la venta del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	74
Tabla N° 31	Pronósticos de la compra y venta del dólar del sistema bancario en moneda nacional para el periodo enero a diciembre 2015, con el modelo de redes neuronales – Perceptrón Multicapa.	75
Tabla N° 32	Comparación de los modelos de Redes Neuronales Artificiales y Box y Jenkins.	76

ÍNDICE DE FIGURAS

Pág

Figura N° 01	Etapas del método univariado de Box y Jenkins	15
Figura N° 02	Modelo de una red neuronal clásica	18
Figura N° 03	Capas de una red neuronal Artificial	21
Figura N° 04	Funciones de activación más comunes de una red neuronal.	22
Figura N° 05	Arquitectura (izquierda) y función de activación (derecha) para el perceptrón multicapa.	24
Figura N° 06	Comportamiento de la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	36
Figura N° 07	Función de autocorrelación simple de la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 20	38
Figura N° 08	Función de autocorrelación parcial de la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014	38
Figura N° 09	Diferencia en 2 periodos de la Trans-logaritmo natural de la serie compra del dólar del sistema bancario, registradas por el BCRP, enero del 2004 a diciembre del 2014.	39
Figura N° 10	Función de autocorrelación simple de la diferencia del logaritmo natural de la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	40

Figura N° 11	Función de autocorrelación parcial de la diferencia del logaritmo natural de la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014	40
Figura N° 12	Correlograma de FAS residual y la FAP residual del modelo ARIMA (2, 2,3) logaritmo natural de la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.	47
Figura N° 13	Serie pronosticada de la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.	49
Figura N° 14	Comportamiento de la venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014	50
Figura N° 15	Función de autocorrelación simple de la venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	51
Figura N° 16	Función de autocorrelación parcial de la venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	51
Figura N° 17	Diferencia en 1 periodo del Logaritmo Natural de la Venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014	52

Figura N° 18	Función de autocorrelación simple de 1 diferencia de la Trans- Logaritmo Natural de la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre del 2014.	53
Figura N° 19	Función de Función de autocorrelación parcial de 1 diferencia del Logaritmo Natural de la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.	53
Figura N° 20	Correlograma de FAS residual y la FAP residual del modelo ARIMA (3,1,2) logaritmo natural de la venta del dólar en el sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.	60
Figura N° 21	Serie pronosticada de la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.	62
Figura N° 22	Arquitectura de Redes Neuronales Artificiales (RNA), de la compra del dólar del sistema bancario en moneda nacional, registrados por el BCR, periodo enero 2004 a diciembre del 2014.	65
Figura N° 23	Arquitectura de Redes Neuronales Artificiales (RNA), de la venta del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.	71

CAPITULO I

INTRODUCCIÓN

Actualmente el precio del dólar está soportando un alza fuerte, la cual beneficiaría nuestra economía, pero daña los balances de los agentes financieros generando un excave en la moneda y la estabilidad del país. Hace buen tiempo el Perú se viene dando una apreciación del tipo de cambio (TC) la moneda peruana nuevo sol y el dólar norteamericano, ante esto se ha emanado reclamos de los sectores que se creen afectados por la alza del precio del dólar, existe diferentes razones por lo que precio del dólar se puede desequilibrar, entre ellas, la políticas cambiarias sostenibles, enorme gasto público, ausencia de ajuste de la economía frente a caídas de términos intercambiaros o durante un proceso de apertura comercial pública y privada. No obstante, en todos ellos, la apreciación cambiaria se produce en un contexto de afluencia de capitales externos y exceso de gastos domésticos. Por lo tanto, el Banco Central de Reserva del Perú (BCRP) viene tomando medidas que tratan de frenar este excéntrico fenómeno para preservar la estabilidad monetaria.

La estabilidad macroeconómica ha sido principalmente para la mejora de la economía peruana. La política cambiaria en la trance utilizó mecanismos como la reducción de las tasas de encaje, inyección de liquidez como las operaciones a plazos fijos de hasta 1 año, swaps de monedas, recompra de los certificados de depósitos BCRP, entre otros. Todo esto para que no imposibilite la demanda de crédito, asegurando que los bancos dispusieran de los recursos y seguir suministrando la actividad financiera para que no repercuta en el tipo de cambio (BCRP, 2017).

La estadística clásica para poder predecir utiliza, con frecuencia, la metodología de Box y Jenkins (Box, Jenkins y Reisel, 2008). Estas metodologías requieren del criterio de un experto, los pasos a realizar dependen del tipo de datos, estos datos deben ser estacionarios, se analizan los gráficos de correlaciones, se evalúa la adecuación del modelo, se mide el error de predicción.

En redes neuronales artificiales ha surgido como una nueva área de conocimientos. Está formada por un conjunto de técnicas que ambicionan imitar, en forma artificial, las habilidades relacionadas con la inteligencia humana. Esta técnica trata de simular el pensamiento humano mediante la conexión de neuronas de la denominada Redes Neuronales Artificiales-RNA, utilizadas recientemente con un relativo éxito para la predicción de series de tiempo.

En el capítulo I, Se explica los fundamentos para la realización de la tesis y se describen los objetivos, el marco teórico y presenta los diversos conceptos necesarios para el correcto entendimiento de la tesis.

En el capítulo II, se describe los materiales y métodos para la pronosticación del precio del dólar del sistema bancario en moneda nacional año 2015

En el capítulo III, se muestran los resultados de la investigación.

del precio del dólar del sistema bancario en moneda nacional año 2015.

En el capítulo IV, se describe, las conclusiones y recomendaciones sobre el modelo de predicción del precio del dólar del sistema bancario año 2015.

1.1 ASPECTOS DE LA PROBLEMÁTICA

1.1.1. Formulación del problema científico:

¿El modelo de Box y Jenkins y Redes Neuronales permite pronosticar el precio del dólar del sistema bancario en moneda nacional año 2015?

1.1.2. Objetivos de estudio:

Objetivo general

Estimar un modelo de Box y Jenkins y Redes Neuronales para pronosticar el precio del dólar del sistema bancario en moneda nacional año 2015.

Objetivos específicos

- Describir el comportamiento del precio del dólar en moneda nacional del sistema bancario año 2015.
- Estimar mediante la metodología de Box y Jenkins; ARIMA el precio del dólar en moneda nacional año 2015.
- Estimar mediante Redes Neuronales Artificiales el precio del dólar en moneda nacional año 2015.
- Comparar las estimaciones con las diferentes metodologías para la predicción del precio del dólar en moneda nacional año 2015.
- Determinar el mejor modelo en series de tiempo para pronosticar el precio del dólar en moneda nacional año 2015.

1.1.3. Antecedentes de la investigación:

Antecedentes locales

Suclupe y Uriarte (2015), presentaron su estudio titulado “Estrategias metodológicas para el pronóstico del tipo de cambio del dólar americano Perú 2009-

2014”, *Tesis* para optar *Titulo en Estadística*, Universidad Nacional Pedro Ruiz Gallo, quienes obtuvieron las siguientes conclusiones: Existen muchas estrategias para la realización de pronósticos, siendo las siguientes: Suavización exponencial simple, Modelo Holt, Winter (Aditivo) y Modelo Arima. La mejor estrategia que se eligió para la pronosticación es el modelo Arima. El modelo que mejor se ajustó fue el siguiente: respecto a la Compra: $(1-B12) FT = (1-0.99412) at + 2.832$; y, respecto a la Venta: $(1-B12) FT = (1-0.99812) at + 2.81$

Antecedentes nacionales

Barrera (2010), en su investigación “Redes neuronales para predecir el tipo de cambio diario”, *Trabajo de Investigación*, Banco Central de Reserva del Perú, obtuvo las siguientes conclusiones: Para contrastar el desempeño predictivo del grupo de modelos disponible se utilizó los errores de predicción cometidos desde agosto hasta setiembre 2008 para estimar secuencias de la raíz del error de predicción cuadrático medio (RECM (h), $h \leq 15$). Este criterio se eligió para evaluar la precisión de las proyecciones y evitar la subjetividad presente en algunas medidas utilizadas en la literatura, como aquellas que usan funciones de pérdida para reflejar las preferencias sobre la precisión demasiado específicas de algunos inversionistas. Como complemento, otras pruebas estadísticas para comparar las bondades predictivas son presentadas. Finalmente, la muestra bajo análisis no incluyó los datos diarios del último trimestre del 2008 debido a que el agravamiento de la crisis financiera global produjo sub-periodos con niveles de volatilidad elevados respecto al periodo de la muestra bajo análisis, los que generaron dificultades en predicción para todos los modelos incluidos en el presente trabajo. La adición de modelos con errores heteroscedásticos, potencialmente útiles en estos sub-periodos de mayor volatilidad, se difiere para una investigación futura.

Cárdenas (2015), en su investigación titulada “Pronósticos y comparación de una serie de tiempo con cambios estructurales mediante la red neuronal artificial de retropropagación resiliente y modelos no lineales”. *Tesis* para optar el *Titulo en Estadística*, Universidad Nacional Mayor de San Marcos, llegó a las siguientes conclusiones: Se puede concluir que el mejor modelo que nos otorga los mejores pronósticos para la serie de tiempo: Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo, es el del segundo modelo No paramétrico, donde se utilizó la metodología de Redes Neuronales artificiales por el método de retropropagación resiliente para los pronósticos del año 2012, por lo que se puede concluir que para nuestra serie de tiempo con cambio estructural la mejor metodología para el caso de pronóstico es la de Redes Neuronales Artificiales. Asimismo, resaltar la gran importancia de la diversidad de software utilizados en esta investigación, en el enfoque paramétrico la utilización del Eviews 8, el SPSS 21, MINITAB 16, STATA 13, y resaltar la importancia del uso del software libre R Project para la estimación y los pronósticos del enfoque no paramétrico, la cual fue de mucha utilidad para la realización de este estudio y el aporte de mi parte hacia el área académica. Por ultimo resaltar la labor de esta investigación, puesto ayuda mucho para una contribución en el área académica, principalmente en la metodología de series de tiempo, la cual cada día existe nuevos métodos que nos ayuda a obtener una mejor estimación y unos buenos pronósticos.

Antecedentes internacionales

Zapata y Díaz (2008), en su estudio titulado “Predicción del tipo de cambio peso-dólar utilizando redes neuronales artificiales”, *Tesis de Maestría*, Universidad Fundación del Norte, Barranquilla (Colombia), llegaron a las siguientes conclusiones: Se ha podido comprobar que es posible realizar predicciones del tipo de cambio peso-

dólar (COP / USD) utilizando Redes Neuronales Artificiales. Se pudo determinar un modelo que muestra la mejor relación existente entre los resultados obtenidos y los tipos de cambio vigentes en las fechas de estudio, el cual está dado por una Red Neuronal Artificial de doce (12) neuronas en la capa de entrada, ocho (8) neuronas en la capa intermedia y una (1) neurona en la capa de salida; con una topología de red multicapa, feedforward o alimentada hacia delante; con un mecanismo de aprendizaje supervisado por corrección de errores; con heteroasociación y representada en forma de valores continuos. De igual forma, el modelo mostró un margen de error promedio de 0.0614%, donde la variable más importante de la predicción fue el IGBC (Índice General de la Bolsa de Valores de Colombia), y la variable con mayor sensibilidad fue Fed Funds Rate (Tasa de Interés de la Reserva Federal de Estados Unidos).

Valencia (2016), en su investigación titulada “Pronóstico de Series de Tiempo con ciclo y tendencia usando Redes Neuronales Artificiales”, *Tesis de maestría*, Universidad Nacional de Colombia, llegó a la conclusión que: La metodología empleada fue comparar el desempeño de hacer los pronósticos en primer lugar con los datos originales, luego un segundo modelo donde el ciclo y la tendencia son eliminados, y un tercer modelo, donde al igual que el modelo anterior, los datos son divididos en componentes, pero se usa un algoritmo regularizado. Estos resultados son comparados con el modelo SARIMA, el cual es un modelo ampliamente utilizado como benchmark para este tipo de problemas.

Torres y Munguía (2016), nos presentan su estudio titulado “Contraste entre modelos de Redes Neuronales Artificiales, GLM y GARCH en el pronóstico y análisis del tipo de cambio mexicano: 2000-2014”, *Tesis para optar Título en Economía*, Universidad Autónoma del Estado De México. Concluyen que: Se estimaron de manera total dos modelos de RNA de tipo multicapa (16:7:2:1 y 17:7:2:1), uno en

forma de serie de tiempo, así como dos modelos para contrastar un lineal GLM y un GARCH (1,1) (los cuales no se desarrollan teóricamente pues no es el objetivo de esta investigación), está dividido en 3 etapas una primera con enfoque de panel, una segunda con enfoque de series de tiempo, y una última donde se estimó una RNA mixta. Utilizando como criterio de comparación RMSE y el error de estimación haciendo uso del valor real del tipo de cambio para enero del 2015.

1.2.MARCO TEÓRICO

1.2.1. Series de Tiempo y Metodología de Box y Jenkins

1.2.1.1. Nociones básicas de series de tiempo

Serie de tiempo se llama así a un conjunto de valores observados durante una serie de periodos temporales secuencialmente ordenada, tales periodos pueden ser días, meses, trimestres y años (Gujarati, 2009).

Los registros son valores numéricos que varían en el tiempo para llevar a cabo un análisis de este tipo, primero se deben identificar la tendencia, la estacionalidad, después aplicar las técnicas estadísticas para su análisis y finalmente, hacer las proyecciones o pronósticos de eventos futuros. También llamada serie cronológica o historia, puede definirse como una sucesión de observaciones de una variable tomados secuencialmente en el tiempo.

Básicamente, lo que se pretende con el estudio de las series temporales es el conocimiento de una variable a través del tiempo, a partir de este conocimiento y bajo el supuesto de que no se van a producir cambios estructurales, para poder realizar predicciones (Makridakis y Wheelwright, 2010).

1.2.2.2. Clasificación de las series de tiempo

Las series temporales se pueden clasificar en Estacionarias y No Estacionarias.

Estacionarias. Una serie es estacionaria cuando es estable a lo largo del tiempo, es decir, cuando la media y la varianza son constantes en el tiempo. Esto se refleja gráficamente en que los valores de la serie tienden a oscilar alrededor de una media constante y la variabilidad con respecto a esa media también permanece constante en el tiempo.

Media:

$$E(Y_t) = E(Y_{t+m}); \text{ para todo } t, m.$$

Varianza:

$$\sigma(Y_t) = \sigma(Y_{t+m}); \text{ para todo } t, m.$$

Covarianza:

$$\text{Cov}(Y_t; Y_{t+k}) = \text{Cov}(Y_{t+m}; Y_{t+m+k}); \text{ para todo } t, m, k.$$

No estacionaria. Son series en las cuales la tendencia y/o variabilidad cambian en el tiempo. Los cambios en la media determinan una tendencia a crecer o decrecer a largo plazo, por lo que la serie no oscila alrededor de un valor medio (BCRP, 2014).

1.2.2.3. Componentes de una serie de tiempo

El supuesto usual es que cuatro componentes separados son: tendencia, cíclico, estacional e irregular, se combinan para proporcionar valores específicos de la serie de tiempo.

Componente Tendencia (Tt). Las series de tiempo pueden seguir mostrando cambios o movimientos graduales hacia valores relativamente mayores o menores en un periodo prolongado. El cambio gradual de la serie de tiempo se conoce como tendencia. Este cambio o tendencia por lo general es el resultado de factores a largo

plazo, como cambios en la población, características demográficas de la población, tecnología y preferencias de consumo.

$$Z_t = \Theta_0 + T_t + a_t \quad t= 1,2,3,\dots,\dots$$

Componente estacional (St). Representa fluctuaciones de la serie en periodos de tiempo inferior a un año que se repiten con periodicidad conocida. Es decir pretende recoger los crecimientos o decrecimientos en los valores de la serie que se producen por el hecho de encontrarnos en una determinada época, en general una estación del año.

$$Z_t = \Theta_0 + T_t + S_t + a_t \quad t= 1,2,3,\dots,\dots$$

Componente cíclico (Ct). se dice las series de tiempo con frecuencia muestran secuencias de puntos que se alteran por encima y por debajo de la línea de tendencia. Cualquier secuencia de puntos recurrentes por encima y por debajo de la línea de tendencia que dura más de un año puede atribuirse al componente cíclico de las series de tiempo.

$$Z_t = \Theta_0 + T_t + S_t + C_t + a_t \quad t= 1,2,3,\dots,\dots$$

Componente irregular o aleatoria. Es el factor residual o “comodín” que incluye las desviaciones de los valores de serie de tiempo reales de aquellos esperados según los efectos del componente cíclico, de tendencia y estacional. Es aquella que no tiene patrones sistemáticos y se comportan impredecible alrededor de su media nula, con una dispersión constante, y se le conoce como proceso de ruido blanco. La componente aleatoria siempre se encuentra presente en toda serie de tiempo y debe encontrarse cuando se logra extraer toda la información en la componente determinista (BCRP, 2017).

$$Z_t = \Theta_0 + T_t + S_t + C_t$$

1.2.2. Pronósticos de serie de tiempo

El pronóstico de las series de tiempo significa que extendemos los valores históricos al futuro, donde aún no hay menciones disponibles, se realiza generalmente para optimizar área como los niveles de inventario, la capacidad de reproducción o los niveles de personal.

Existen dos variables principales que definen un pronóstico de serie de tiempo.

El periodo. Representa el nivel de agregación. Los periodos más comunes son los meses, semanas y días en la cadena de suministros (pronóstico de incremento del dólar). Los centros comerciales, centros bancarios utilizan los periodos más comunes para pronosticar días, meses, años de nivel de producción, ingreso económico, etc.

El horizonte. Representa la cantidad de periodos por adelantado que se deben ser pronosticados. En la cadena de suministro, el horizonte es generalmente igual o mayor que el tiempo de entrega (Barrera, 2010).

Los diferentes pronósticos son utilizados en diferentes áreas como:

- Administración de riesgo financiero
- Economía
- Especulación financiera
- Planeación de capacidad
- Planeación y control de operaciones.

1.2.3. Metodología de Box y Jenkins

La metodología de Box y Jenkins para generar pronósticos es diferente de la mayoría de los métodos. Esta técnica no asume ningún patrón particular en los datos históricos de la serie a pronosticar. Utilizan un enfoque iterativo de identificación de

un modelo útil a partir de modelos de tipo general. El modelo elegido se verifica contra los datos históricos para ver si se describe la serie con precisión. El modelo se ajusta bien si los residuos entre el modelo de pronóstico y los puntos de datos históricos son reducidos, distribuidos de manera aleatoria e independiente. Si el modelo indicado no es satisfactorio, se repite el proceso utilizando otro modelo diseñado para mejorar el original. Este proceso se repite hasta encontrar un modelo satisfactorio. (Hanke y Reitsh, 2014).

1.2.4. Modelos ARIMA

Los modelos ARIMA o modelos de promedio móvil autorregresivo integrado son un tipo general de los modelos de Box y Jenkins para series de tiempo estacionarias. Una serie histórica estacionaria es aquella cuyo valor promedio no cambia a través del tiempo. Este incluye a los modelos AR solo con términos autorregresivos, los modelos MA solo con términos de promedio móvil. La metodología de Box – Jenkins permite al analista seleccionar el modelo que mejor se ajusta a sus datos.

Las técnicas de Box y Jenkins aplican métodos autorregresivos y de promedio móvil. A los problemas de pronóstico de series de tiempo (Hanke y Reitsh, 2014)

Modelo Autorregresivo (AR)

El modelo autorregresivo toma la forma:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

En donde:

Y_t : Variable dependiente en el tiempo.

$Y_{t-1}, Y_{t-2}, \dots Y_{t-p}$: Variables independientes que son variables dependientes desfasadas un número específico de periodos.

$\phi_0, \phi_1, \phi_2, \dots \phi_p$: Coeficientes que serán estimados

ε_t : Término de residuo que representa sucesos aleatorios no explicados por el modelo.

Modelo de Promedio Móvil (MA).

Un modelo de promedio móvil toma la forma:

$$Y_t = w_0 + \varepsilon_t - w_1\varepsilon_{t-1} - w_2\varepsilon_{t-2} - \dots - w_q\varepsilon_{t-q}$$

En donde:

Y_t : Variable dependiente.

$w_0, w_1, w_2, \dots w_q$: Coeficientes.

ε_t : Residuo o error.

$\varepsilon_{t-1}, \varepsilon_{t-2}, \dots \varepsilon_{t-q}$: Valores previos de residuos.

Modelos autorregresivos de promedio móvil (ARIMA)

Además de los modelos AR y MA, ambos se pueden combinar en un tercer tipo de modelo general denominado ARIMA

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t - w_1 \varepsilon_{t-1} - w_2 \varepsilon_{t-2} - \dots - w_q \varepsilon_{t-q}$$

Los modelos ARIMA (p,d,q) utilizan combinaciones de errores anteriores y valores anteriores y ofrecen un potencial para ajustar modelos que no pudieron ajustarse en forma adecuada mediante los modelos AR y MA por si solos (Hanke, J. y Reits,A. 2014)

Modelos ARIMA estacionales (SARIMA)

Muchas series económicas si se observan varias veces a lo largo del año, trimestral o mensualmente, presentan comportamiento estacional. Este tipo de comportamiento puede ser debido a factores meteorológicos, costumbres o fenómenos sociales.

A la hora de elaborar el modelo ARIMA adecuado para una serie temporal se ha de tener el comportamiento estacional, si los hubiere, porque implica que la observación de un mes y la observación del mismo año anterior tiene una pauta de comportamiento similar por lo que estarían temporalmente correlacionadas.

Por lo tanto, el modelo de series de temporales ARIMA apropiado para este tipo de series debería recoger las dos clases de dependencia inter temporal que presenta a saber:

La relación lineal existe entre observaciones sucesivas (comportamiento tendencial o regular) y, la relación lineal existente entre observaciones del mismo mes en años sucesivos (comportamiento estacional) (Gujarati y Porter, 2010).

Coefficientes de autocorrelación y autocorrelación parcial de los modelos AR (1) y AR (2)

$$\text{AR (1)} \quad y_t = \phi_0 + \phi_1 y_{t-1} + \varepsilon_t$$

$$\text{AR (2)} \quad y_t = \phi_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \varepsilon_t$$

Coefficientes de autocorrelación y autocorrelación parcial de los modelos MA (1) y MA (2)

$$\text{MA (1): } y_t = \omega_0 + \varepsilon_t - \omega_1 \varepsilon_{t-1}$$

$$\text{MA (2): } y_t = \omega_0 + \varepsilon_t - \omega_1 \varepsilon_{t-1} + \omega_2 \varepsilon_{t-2}$$

Función de autocorrelación

La autocorrelación es una herramienta matemática utilizada frecuentemente en el procesamiento de las señales, la función de autocorrelación, se define como la correlación cruzada de la señal consigo mismo. La función de autocorrelación resulta de gran utilidad para encontrar patrones repetitivos dentro de una señal, como la periodicidad de una señal enmascarada bajo un ruido blanco o para identificar la frecuencia fundamental de una señal que contiene dicha componente. En estadística la autocorrelación de una serie temporal de un proceso y_t es simplemente la correlación de dicho proceso con una versión desplazada en el tiempo de la propia serie temporal

Si y_t representa un proceso estacionario de segundo orden con un valor principal de μ se define entonces la función de autocorrelación. (Hanke y Reith, 2014).

$$R(K) = \frac{E[(Y_i - \mu)(Y_{i-k} - \mu)]}{\sigma^2}$$

Tabla N° 01

Comportamiento de la Función de Autocorrelación (ACF) y la Función de Autocorrelación Parcial (ACFP).

FUNCION	AUTOCORRELACION (ACF)	AUTOCORRELACION PARCIAL (ACFP).
AR(P)	Decrecimiento rápido a cero en forma geométrica, exponencial o sinusoidal.	Se anula para retardos superiores a p
MA(q)	Se anula para retardos superiores a p .	Decrecimiento rápido a cero en forma geométrica, exponencial o sinusoidal.
ARMA(p,q)	Los primeros valores iniciales no tienen patrón fijo y van seguidos de una mezcla de oscilaciones sinusoidales y/o exponenciales.	Los primeros valores iniciales no tienen patrón fijo y van seguidos de una mezcla de oscilaciones sinusoidales y/o exponenciales.

Fuente: Elaboración Propia, 2017

1.2.5. Estrategia de Modelización ARIMA

Para construir un modelo ARIMA que recopile adecuadamente las características de la serie se hace uso de la metodología de Box y Jenkins que puede ser estructurada en etapas:

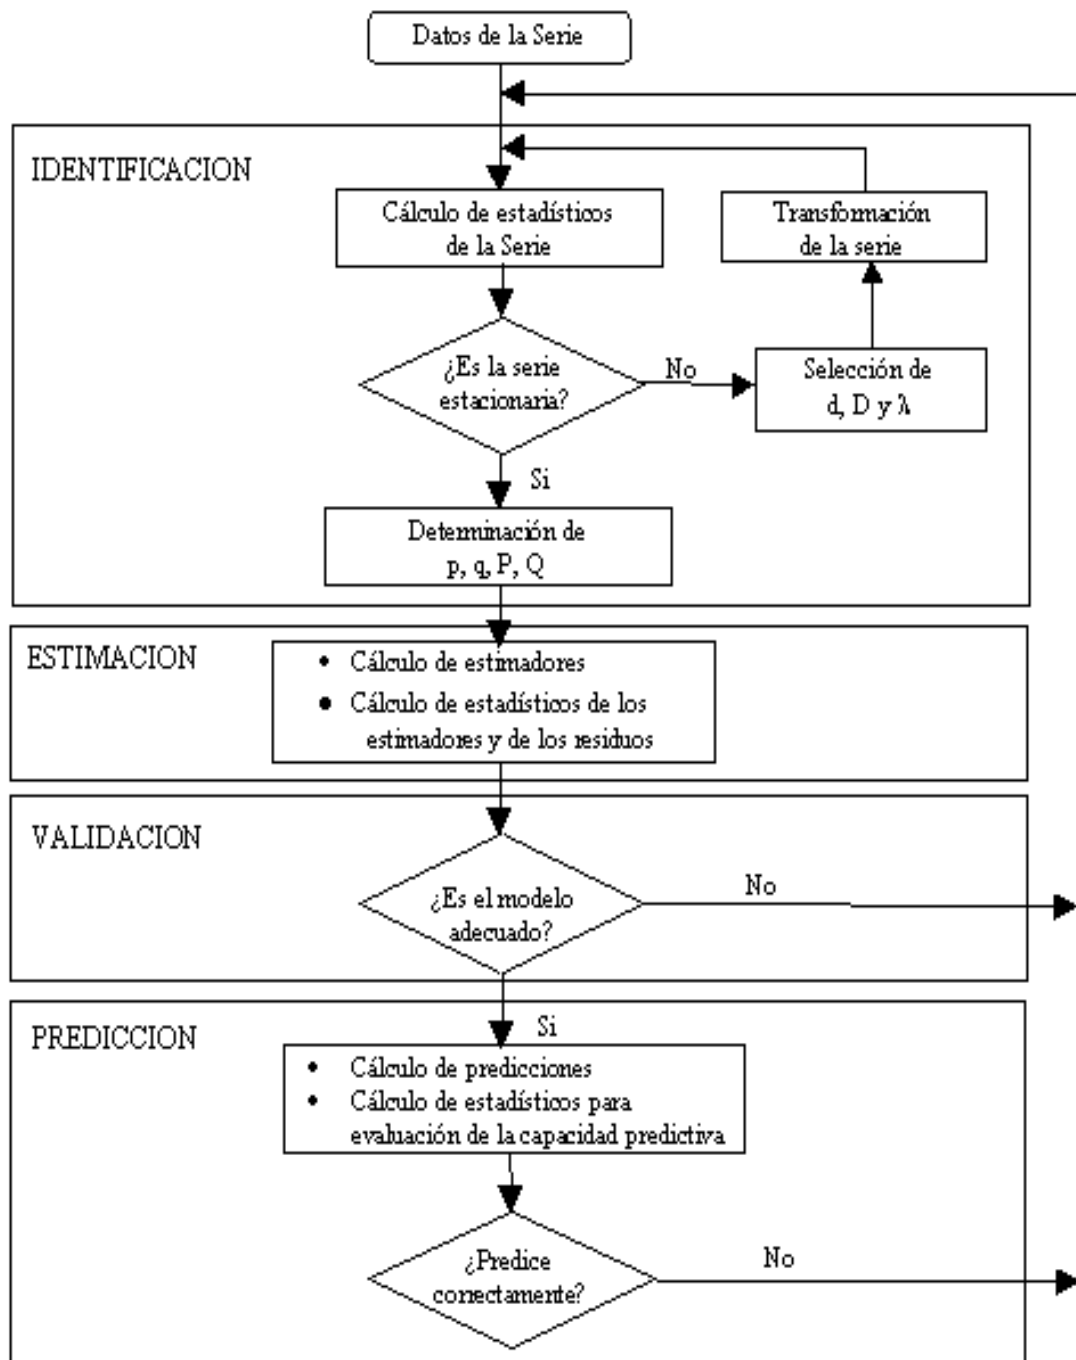


Figura N°01: Etapas del método univariado de Box y Jenkins

Etapas de identificación

En esta etapa determinamos si la serie es estacionaria, es decir, si la serie de tiempo parece variar alrededor de un nivel fijo,

La idea básica para utilizar estas funciones de autocorrelación es la siguiente: cada modelo ARIMA tiene asociadas unas funciones de autocorrelación teóricas. En esta etapa comparamos las funciones de autocorrelación estimadas con las teóricas y elegimos como modelo tentativo aquel al que más se aproximen ambas. El modelo que obtengamos es, como se ha dicho anteriormente, tentativo y debemos realizar el resto de las etapas para comprobar que realmente es el adecuado. (Hanke y Reitsch, 2014).

Etapas de estimación

En esta etapa obtenemos las estimaciones de los parámetros del modelo ARIMA, una vez hemos fijados en la etapa de identificación los órdenes autorregresivo y de media móvil. Esta estimación se realiza mediante minimización cuadrática del error de ajuste. Esta etapa nos proporciona señales de aviso sobre si el modelo es Adecuado o no. En particular, si los coeficientes no cumplen ciertas inecuaciones derivadas de la invertibilidad y la estacionalidad, el modelo ajustado debe ser rechazado.

Etapas de validación

Box y Jenkins proponen algunas comprobaciones de hipótesis que deben ser realizadas para comprobar que el modelo estimado es Estadísticamente adecuado. Algunas de las comprobaciones que se deben realizar son que los residuos cumplen las hipótesis de ruido blanco o que no existen coeficientes no significativos.

Una vez hemos comprobado que el modelo es correcto, podemos realizar predicciones usando el mismo.

Para solventar el problema de la identificación mediante comparación de funciones de autocorrelación, hay desarrollos de algoritmos que unen la etapa de identificación y estimación. Así se logra poder orientar el desarrollo del algoritmo a medidas de error y comprobación de hipótesis del modelo. Mediante estos algoritmos podemos ajustar de una manera correcta modelos ARIMA con órdenes altos.

Etapas de la predicción

Para realizar predicciones puntuales mediante un modelo ARIMA, se utiliza la notación algebraica. Se resuelve la ecuación para Y_t . Para ello se introducen las estimaciones de la constante del modelo y de los parámetros ϕ y θ y se asigna cero como valor esperado del error ε_t . Lo que se realiza a continuación es insertar los valores. Pasados de Y_t y de los errores. En la práctica debemos usar como errores los obtenidos en la etapa de estimación y, si el periodo de Predicción es mayor que el orden de media móvil, asignaremos a las estimaciones de los errores el valor nulo. De igual modo utilizaremos las predicciones de Y_t en el caso de que el periodo de predicción sea mayor al orden autorregresivo. (Gujarati, D. y Porter, D. 2010).

1.2.6. Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (RNA) están inspiradas en las redes neuronales biológicas del cerebro humano y constituido por elementos que se comportan de forma similar a la neurona biológica en sus funciones más comunes (Basogain, 2014).

Las redes neuronales es un área del conocimiento compuesta por un conjunto de técnicas que se basan en imitar computacionalmente las distintas habilidades relacionadas a la inteligencia del ser humano. Por lo que hace un reconocimiento de patrones, diagnósticos, clasificaciones, identificación o predicción.

El objetivo es conseguir que las máquinas den respuestas similares a las que es capaz de dar el cerebro que se caracterizan por su generalización y su robustez.

Los modelos más usados para pronósticos de series de tiempo con redes neuronales es el Perceptrón Multicapa. Las redes neuronales basadas en el Perceptrón multicapa han sido capaces de demostrar que se comportan como un aproximado universal de funciones (Khashei y Bijari, 2011).

1.2.7. Modelo de una Red Neuronal Artificial

Una red neuronal es un modelo simplificado que emula el modo en que el cerebro humano procesa la información: Funciona simultaneando un número elevado de unidades de procesamiento interconectadas que parecen versiones abstractas de neuronas.




Figura N° 02: Modelo de una Neurona Neuronal Clásica

1.2.8. Elementos de una neurona

Una neurona o la evolución de la forma de emular de una neurona como funciona como en el cerebro en esa conexión neuronal que tenemos en nuestro cerebro

lo que hacemos es intentar hacer entradas y en esas entradas vamos analizarlas en ese análisis lo único que vamos hacer un sumatorio de los valores de las entradas lo ocurre es que vamos a modular esos valores de las entradas mediante unos factores que denominamos pesos w_1, w_2, \dots, w_n y además se añade un valor independiente es un valor que va a modificar como sumatorio la salida luego la salida de la neurona va hacer el resultado de los productos de las entradas por sus términos independientes más el termino independiente y todo esto modulado con una función determinada.

1.2.9. Arquitectura de Redes Neuronales Artificiales

Se denomina arquitectura a la topología, a la estructura o patrón de conexiones de una red neuronal artificial. En una red neuronal artificial los nodos se conectan por medio de sinapsis, estando el comportamiento de la red determinado por la estructura de conexiones sinápticas. Estas conexiones sinápticas son direccionales, es decir, la información solamente puede propagarse en un único sentido (desde la neurona presináptica a la pos- sináptica). En general las neuronas se suelen agrupar en unidades estructurales que denominaremos capas. El conjunto de una o más capas constituye la red neuronal artificial. (Cárdenas, 2015)

1.2.10. Capas de las redes neuronales artificiales

Capa de entrada (X_j)

Es la capa que tiene como función la de recibir información externa, en otras palabras, recibe los datos de entrada para resolver el problema, Sus características son:

- Ser de carácter única.
- Tiene un número de neuronas definido por la cantidad de inputs

- Propaga los datos a la capa siguiente, por lo que esta capa no se realiza ningún proceso, salvo la aplicación de una función escalar a través de las funciones de activación o de transferencia que se detallará más adelante.

Capa oculta

Es la capa donde se procesan los datos del problema de análisis. Sus características son:

- No posee carácter único, por lo que puede existir más de una en la arquitectura de la red neuronal artificial.
- Posee un número de neuronas artificiales determinado por quien lo aplica la red.
- Los datos se propagan a la capa siguiente previa al acto de una función de activación o de transferencia.
- Esta capa no posee conexión directa con el entorno o exterior.

Capa de salida (Yj)

Es la capa formada por las neuronas que proporcionan la respuesta al problema en cuestión, es decir, donde se representa el resultado entregado por la red neuronal artificial. Sus características son:

- Ser de carácter única.
- Posee un gran número de neuronas definido por la cantidad de outputs.
- En esta capa, las neuronas aplican la función de activación o de transferencia a los datos recibidos, antes de entregar el producto final
- En los modelos más simples hay una salida

- Donde esta forma, la salida producida por una neurona i , para una determinado instante de tiempo t pueden ser escrita en forma general de la siguiente manera (Morales, 2008).

$$y_i(t) = F_i(a_i(t)) = a_i(t)$$

Peso sináptico (W_{ij})

Representan el grado de comunicación entre la neurona artificial j y la neurona artificial i . Pueden ser excitadores o inhibidores.

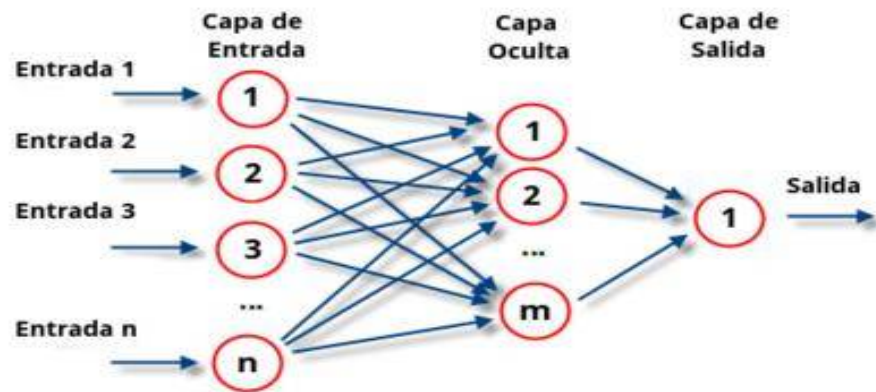


Figura N° 03: Capas de una red neuronal Artificial

1.2.11. Funciones de las Redes Neuronales Artificiales

Función de propagación

También conocida como función de excitación, que por lo general consiste en la entrada (suma de todas las señales de entrada) multiplicada por el peso de su interconexión. Si el peso es positivo, la conexión se denomina excitatoria; si es negativo, se denomina inhibitoria.

$$h_i(t) = \sum_j w_{ij} x_{ij}$$

Función de activación o Función de transferencia

La función de activación o de transferencia describe las formas en que se procesa el input en los nodos. La no linealidad de la función de transferencia es la que otorga a la red neuronal la flexibilidad y, por lo tanto, las ventajas en modelización de series temporales financieras sobre las técnicas tradicionales de regresión. (Panahian, H. 2001). De esta forma, la “función de activación o transferencia” será aquel elemento de la topología de una red que permite calcular el estado de actividad de una neurona artificial, cuyo rango más utilizadas normalmente son la función sigmoidea (para obtener valores de (0 a 1) dependiendo de su estado de activación o inactividad. Así, una neurona podrá estar, totalmente inactiva (0 ó -1), o totalmente activa (1). y la tangente hiperbólica (para obtener valores en el intervalo [-1,1]).

$$a_i(t) = f_i(n_i(t))$$

A continuación, se presentarán las funciones de activación más comunes




Figura N° 04: Funciones de activación más comunes de una red neuronal.

1.2.12. Clasificación de las Redes Neuronales Artificiales

Supervisados. Consiste en representar un conjunto de patrones a la red, junto con la salida deseada u objeto. De esta forma, la red es capaz de ajustar los pesos sinápticos de las neuronas hasta que su salida tiende a ser deseada, utilizando para ello información detallada del erro que comete a cada paso. Así, la red neuronal artificial es capaz de estimar relaciones entrada/salida sin necesidad de proponer una cierta forma funcional a priori.

No supervisados. Se le representa a la red neuronal artificial una multitud de patrones, sin adjuntar la respuesta deseada. Así durante el proceso de aprendizaje, la red neuronal artificial debe descubrir por si sola los rangos comunes, regularidades, correlaciones o patrones según similitud y, de esta forma, incorporarlas a su estructura interna de conexiones (pesos sinápticos). Se dice, por lo tanto, que las neuronas artificiales deben auto organizarse en función de estímulos (señales o datos) procedentes del exterior. Par obtener resultados la calidad de la red requiere de un cierto nivel de redundancia en las entradas procedentes del exterior, en definitiva, de un número de patrones de aprendizaje suficiente.

Tipos de Redes Neuronales Artificiales.

- Perceptrón
- Adaline, peceptrón, madaline
- Perceptrón multicapa
- Redes de hopfield
- Mapas asociativos, Redes de Kohonen
- Redes neuronales con ligadura funcional

Para el estudio para la pronosticación del dólar utilizaremos la perceptrón multicapa. (Castillo, 2016)

Perceptrón Multicapa.

El perceptrón multicapa es una red neuronal artificial formada por múltiples capas, esto le permite resolver problemas que no son linealmente separables. La salida de una neurona está determinada por la suma ponderada con las salidas de las neuronas de la capa anterior y una función de activación (Bustos, 2014).

Soluciona la separabilidad en regiones convexas y precisa del algoritmo de retro propagación (Castillo, J. 2016).

$$W_{t+1} = W_t + n x_k (y_k - W_t x_k)$$

w_t = peso anterior

n = coef. Aprendizaje variable

x_k =valor de la entrada

y_k =valor esperado de salida

$w_t x_k$ = sumatorio de los pesos por sus entradas



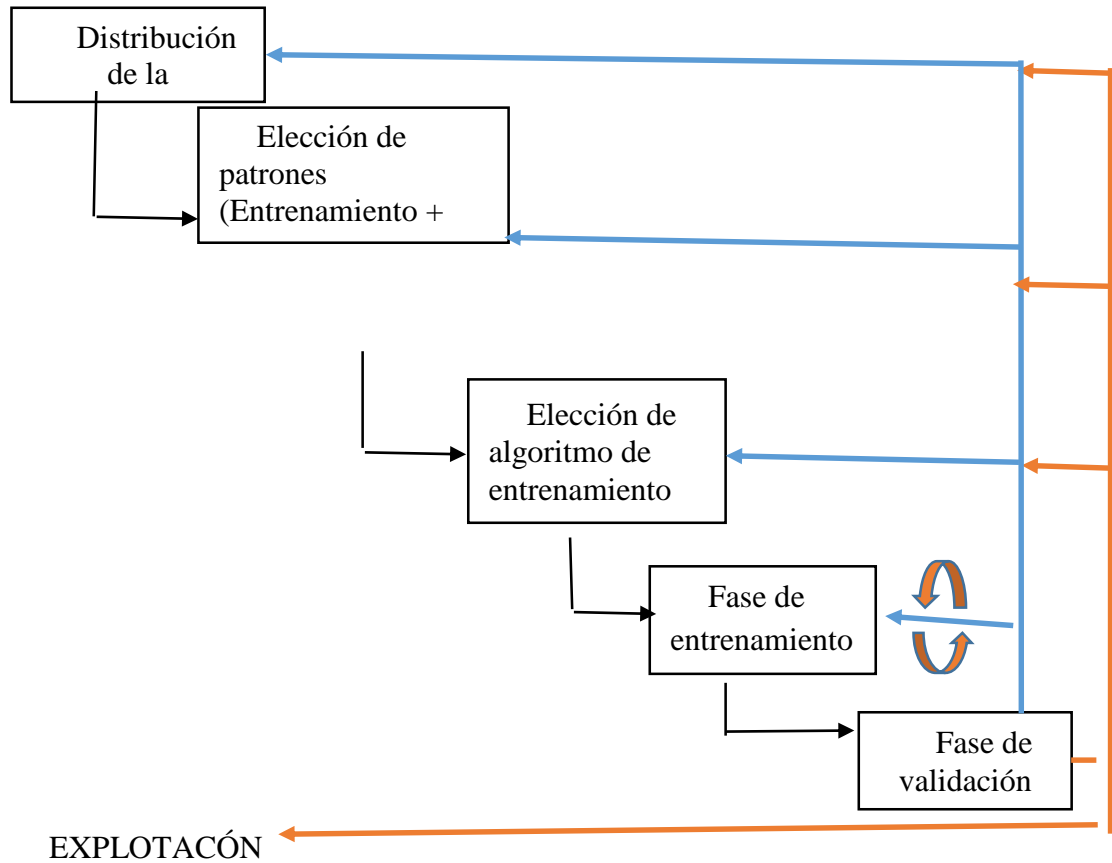


Figura N° 5: Arquitectura (izquierda) y función de activación (derecha) para el perceptrón multicapa.

Fases del diseño de Perceptrón Multicapa.



1.2.13. Características de las Redes Neuronales Artificiales.

- Alto paralelismo
- Fácil implementación de HW
- Robustez frente a fallos
- Capacidad de generalización
- Naturaleza adaptativa (aprendizaje)

1.2.14. Tipo de cambio

El tipo de cambio mide el valor de una moneda en términos de otra; en nuestro caso, el dólar de los estados unidos de américa con respecto al nuevo sol. Es un régimen de flotación, el tipo de cambio refleja variaciones en la oferta y la demanda de divisas. En tal sentido, esta variable está influida, entre otros factores, por la evolución de los términos de intercambio, los volúmenes d comercio exterior, los flujos de capital y cambios en las decisiones de portafolio de la persona, empresa y bancos que están ligados al sector económico (BRCP, 2017).

Tipo de cambio bancario. Se considera que es un promedio ponderado de las operaciones del día en el sistema bancario, publicado por la superintendencia de banca y seguro (SBS).

Tipo de cambio interbancario. Corresponde a la cotización de la oferta y la demanda del dólar de estados unidos de américa, de las operaciones entre las entidades bancarias.

Tipo de cambio informal. Está determinado por la oferta y la demanda del mercado informal de divisas.

El mercado cambiario o de divisas no es más que como cualquier otro mercado un mecanismo por medio del cual demandantes y ofertantes intercambian bienes y servicios, que este caso se refieren a las divisas. El tipo de cambio es el precio relativo, es decir, el precio de una moneda que se expresa en términos de la unidad de otra moneda.

Modalidad de tipo de cambio

Entre las modalidades de tipo de cambio se encuentran

- Tipos de cambios rígidos y flexibles

- Tipos de cambio fijo y variable.
- Tipo de cambios únicos y múltiples.

Cambio rígido

El tipo de cambio rígido es aquel cuyas fluctuaciones están contenidas dentro de un margen determinado. Este es el caso de patrón oro, en que los tipos de cambio pueden oscilar entre los llamados puntos o límites de exportación e importación de oro, por arriba o por debajo de la paridad. Si los tipos de cambio excedieran de dichos límites ocurrirían movimientos de oro que harían volver las cotizaciones al margen determinado.

Su funcionamiento exige la posibilidad concreta de dichos movimientos de oro y se asegura, además, mediante un mecanismo operativo de movimientos de capital a corto plazo, ligados a una relación entre los tipos de cambio y las tasas monetarias de interés.

Cambio flexible

El tipo de cambio flexible es aquel cuyas fluctuaciones no tienen límites precisamente determinados, lo que no significa que tales fluctuaciones sean ilimitadas o infinitas. Este es el caso del patrón de cambio puro y del papel moneda inconvertible. Son los propios mecanismos del mercado cambiario y, en general, la dinámica de las transacciones internacionales del país, los que, bajo la condición esencial de la flexibilidad, permiten una relativa estabilidad de los cambios, dadas las elasticidades de oferta y demanda de los diversos componentes de la balanza de pagos.

Cambio Fijo

Es aquel determinado administrativamente por la autoridad monetaria como el Banco Central o el Ministerio de Hacienda y puede combinarse tanto con demanda

libre y oferta parcialmente libre, como con restricciones cambiarias y control de cambios.

Dado el virtual quebrantamiento del patrón oro en nuestros días, la alternativa de la flotación de los cambios es la fijación por la autoridad. La variabilidad de los tipos de cambios puede interpretarse en sentido restringido (como en el caso del patrón oro) o en sentido amplio (como en régimen de patrón de cambio y de papel moneda inconvertible).

Cambio único

El tipo de cambio único, como su nombre lo indica, es aquel que rige para todas las operaciones cambiarias, cualquiera que sea su naturaleza o magnitud. Se tolera cierta diferencia entre los tipos de compra y de venta de la divisa como margen operativo para los cambistas en cuanto a sus gastos de administración y operación y beneficio normal. El ideal del FMI es el sistema de cambios únicos, que no admite discriminación en cuanto a las fuentes de origen de las divisas ni en cuanto a las aplicaciones de las mismas en los pagos internacionales. De modo distinto, los tipos de cambios múltiples o diferenciales permiten la discriminación entre vendedores y entre compradores de divisas, de acuerdo con los objetivos de la política monetaria, fiscal o económica en general. Mediante este sistema puede favorecerse determinadas exportaciones (con tipos de cambio de preferencia que proporcionen más moneda nacional por unidad de moneda extranjera a los respectivos exportadores), determinadas entradas de capital, o restringirse determinadas importaciones o salidas de capital y otras transacciones internacionales. Es un sistema frecuentemente utilizado por los países no desarrollados como un instrumento auxiliar de la política de crecimiento económico.

1.2.15. El Dólar

El dólar estadounidense es la moneda oficial de los Estados Unidos y el monopolio de la emisión de dólares americanos se encarga el Federal Reserve System (Fed), es el Banco Central de los Estados Unidos. Su valor está respaldado únicamente por la confianza que le otorgan los usuarios. (Fed, 2017).

Moneda “Nuevos Soles”



Cabeza de Vaca
(Tumbes)



Cerámica
Shipibo - Konibo
(Ucayali)



Arco Parabólico
(Tacna)

Dólar Norteamericano



CAPÍTULO II

MATERIALES Y METODOS

En el trabajo de investigación, se describe la metodología de la investigación que se ha desarrollado con la recolección de datos que nos proporcionaron y así mismo verificados por la página web www.bcrp.gob.pe para lograr un modelo de predicción y lograr obtener los objetivos propuestos.

2.1. Tipo de Investigación:

La investigación es de tipo Descriptiva, predictiva-Longitudinal.

2.2. El Diseño de la Investigación:

El diseño es el no experimental

2.3. Variables

Variable dependiente:

El precio del dólar del Sistema Bancario en moneda nacional año 2015.

Variable independiente: Tiempo (Años / Meses)

En la presente investigación, la variable independiente es el tiempo en cual esta medido en meses, desde enero del año 2004 hasta diciembre del año 2014, registrados en la base de datos del BCRP

2.4. Población

Precio del dólar del sistema bancario en moneda nacional en el Perú.

2.5 Muestra

La muestra de estudio estuvo constituida por la serie histórica del precio del dólar del sistema bancario correspondiente a los meses de enero 2004 hasta diciembre 2014.

Las series se obtuvieron de la página web del Banco Central de Reserva del Perú (BCRP). www.bcrp.gob.pe.

2.6. Métodos, Técnica e Instrumento de Recolección de Datos

En la presente investigación la principal fuente de información fue la serie histórica que contiene la variable precio del dólar en el sistema bancario seleccionada para el estudio, la cual se obtuvo del Banco Central de Reserva del Perú y como técnica de recolección de datos se obtuvo la creación de una base de datos en Excel, la misma que fue procesada utilizando los softwares estadísticos SPSS 22.

Metodología de Box y Jenkins

La metodología que se utilizó para encontrar el modelo de pronóstico del Precio del Dólar del Sistema Bancario en Moneda Nacional Año 2015 para que sea satisfactorio fue la de Box y Jenkins.

2.7. Procesamiento Estadístico

Para realizar comparaciones descriptivas de las series, se calcularán promedios, varianzas, desviaciones estándar y coeficientes de variación, con el software SPSS 22.

Las siguientes son las etapas de la metodología ARIMA de manera más precisa, incluyendo los modelos estadísticos descriptivos e inferenciales que se utilizarán:

1. Identificación del modelo

Gráfico de la serie a fin de observar su comportamiento en su estacionariedad, tendencia y estacionalidad.

La identificación del modelo también consistirá en determinar las componentes del modelo ARIMA (p, d, q), donde:

p: Número de componentes autorregresivos AR (p) no estacionales.

d: Número de diferencias no estacionales.

q: Número de componentes de promedio móvil MA (q) no estacionales.

En la identificación del modelo también se incluirá:

La Prueba de Kolmogorov Smirnov

Se utilizará la Prueba de Kolmogorov Smirnov para establecer si la serie diferenciada es estacionaria, para ello se utilizará el software estadístico SPSS 22.

2. Estimación

La estimación del modelo propuesto se realizará empleando el programa estadístico SPSS versión 22. El programa se eligió por su versatilidad para facilitar la técnica de “prueba y error” en la identificación del modelo, permitiendo además realizar pronósticos y grabar datos como los coeficientes estimados, los valores estimados y los residuales, lo que permite una verificación posterior de la bondad de ajuste del modelo estimado.

Para identificar los componentes autorregresivos y de promedio móvil se analizarán los gráficos de las Funciones de autocorrelación total (FAC) y de autocorrelación parcial (FACP).

3. Adecuación del modelo

Se analizará la adecuación del modelo propuesto teniendo en cuenta los siguientes indicadores:

Pruebas de significancia de los coeficientes del modelo.

Cuantificación del error de estimación del modelo.

Análisis de los residuales, que comprende:

La estadística de Ljung-Box, realizada sucesivamente para los rezagos 12, 24 y 36, con la finalidad de establecer si los errores son independientes a través del tiempo, cuya fórmula está dada por:

$$Q_{LB} = T(T+2) \frac{\sum_{j=1}^K r_j^2}{T-j}, \text{ donde:}$$

T: Longitud de la serie de tiempo.

K: Numero de rezagos que se analizan (k=12, 24, 36)

r_j: Coeficientes de autocorrelación.

Evaluación de la función de Autocorrelación (FAC) y de la función de autocorrelación parcial (FACP) de los residuales.

Normalidad de residuales: prueba de Kolmogorov – Smirnov; además, de los métodos gráficos (papel probabilístico, histograma y ploteo con los valores pronosticados y los distribuidos en el tiempo).

4. Pronóstico con el modelo

Con el modelo estimado se realizarán los pronósticos del precio del dólar del sistema bancario para los meses de enero a diciembre del 2015.

5. Validez del pronóstico

Los pronósticos que se realicen con el modelo estimado para los meses de enero a diciembre del 2015, se compararán con los datos reales del precio del dólar del sistema bancario para esos meses y que han sido reportados por el Banco Central de Reserva del Perú (BCRP).

Las técnicas con que se evaluarán los errores de pronóstico serán:

Error absoluto promedio (MAE).

Raíz del error cuadrático promedio (RMSE).

Error absoluto porcentual promedio (MAPE).

Redes Neuronales Artificiales.

En Redes Neuronales Artificiales en series de tiempo, no requiere ningún tipo de parámetro, es decir, es una técnica no paramétrica, las series de tiempo que se ha considerado para el uso de esta técnica es el pronóstico del Precio del Dólar del Sistema Bancario en Moneda Nacional Año 2015. A continuación, se representan los resultados y el modelo obtenido a través de la aplicación de Redes Neuronales Artificiales.

1. Definición de la arquitectura

Es la estructura de la red. Para los ocho modelos de redes neuronales artificiales el número de variables de entrada son las mismas, 12, representa los meses de Enero a Diciembre para la compra del dólar del sistema bancario en moneda nacional, las capas ocultas para la compra y la venta tienen 1 capa en la red, para la compra el caso del modelo 1 está compuesta por 5 nodos, modelo 2 por 4 nodos, modelo 3 por 2 nodos y el modelo 4 por 1 nodo y para la venta para el caso del modelo 1 está compuesta por 6 nodos, modelo 2 por 5 nodos, modelo 3 y 4 está compuesta por 2 nodos.

2. Elección de patrones

Entrenamiento. El tipo de entrenamiento determina el modo en que la red procesa los datos, para la compra y venta del dólar del sistema bancario en moneda nacional para cada modelo se ha especificado Mini lote, en lote y en línea.

Función de activación. Para la función activación de la capa oculta de los 4 modelos de la compra del dólar del sistema bancario en moneda nacional y 4 modelos de la venta de redes se ha utilizado la tangente hiperbólica tomando un argumento de $[1,-1]$.

Error absoluto promedio. Luego de realizar el pronóstico y evaluar el error de cada uno de los modelos de la compra y venta del dólar del sistema bancario en moneda nacional se toma el menor error absoluto.

3. Elección de algoritmo de entrenamiento para el modelo de la red Neuronal Artificial.

Tipo de escala. La variable independiente o covariables, para la compra y la venta es el precio del dólar del sistema bancario en moneda nacional, desde enero 2004 hasta diciembre del 2014, las variables ya han sido transformadas (normalizados), es decir han quedado comprendidos entre 0 y 1.

Arquitectura. La estructura de la red está compuesta por una capa oculta compuesta por 5 nodos para la compra y para la venta compuesta por 6 nodos.

4. Fases de entrenamiento

Entrenamiento. El tipo de entrenamiento es por mini lotes. El algoritmo de optimización es el método utilizado para estimar las ponderaciones sinápticas, el algoritmo utilizado es pendiente de gradiente, hace referencia a la velocidad con que la red entrena teniendo en cuenta los parámetros.

Opción	Valor
Tasa de aprendizaje inicial	0,4
Límite inferior de la tasa de aprendizaje	0,001
Reducción de la tasa de aprendizaje, en Épocas	10
Impulso	0,9
Centro de intervalo	0
Desplazamiento de intervalo	± 0.5

CAPÍTULO III

RESULTADOS Y DISCUSION

Tabla N° 02

Estadísticos descriptivos de la compra y venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

ESTADISTICO	COMPRA	VENTA
Media	2.982	2.987
Desviación típica	0.261	0.258
Coefficiente de variación	8.75%	8.64%
Mínimo	2.551	2.565
Máximo	3.486	3.488
N° validos	132	132

Fuente: BCRP, 2017 - Elaboración propia.

En la tabla N° 02, se presentan los estadísticos descriptivos, donde se observa que la compra y venta del dólar del sistema bancario, registrados por el BCRP, periodo enero del 2004 a diciembre del 2014, tienen un promedio de 2.982 y 2.987 dólares, con una desviación típica de ± 0.261 y ± 0.258 , un coeficiente de variación de 8.75% y 8.64%, es decir los datos de la compra y venta del dólar son homogéneos en torno a la media.

3.2 Resultados tipo de cambio de la compra del dólar mediante la metodología de Box y Jenkins

Paso N° 1 Grafica de la serie original




Figura N° 06

Comportamiento de la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

En la figura N° 06, se observa que el comportamiento de la compra del dólar tiene una tendencia decreciente hasta diciembre del 2012, apreciándose claramente la no estacionariedad de la serie, además muestran componente de tendencia y se observa en la serie que hay estacionalidad. En consecuencia se tiene que realizar transformación u diferenciación a la serie original para poder aplicar la metodología de box y Jenkins.

Paso N° 2 Correlograma total de la serie original




Figura N° 07

Función de autocorrelación simple de la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

En la figura N° 07

Se observa el correlograma de la función de autocorrelación simple de la compra del dólar del sistema bancario, donde los retardos descienden lentamente a cero, indicando que no son independientes. Por lo tanto, es necesario transformar la serie original. (Ver Anexo B)




Figura N° 08

Función de autocorrelación parcial de la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

En la figura N° 08

Se observa la función de autocorrelación parcial descendiendo rápidamente a cero con un retardo significativo que sobresale los límites de confianza al 95%, por lo que indica que es posible que exista parte autorregresivo en los modelos de pronósticos para la compra del dólar del sistema bancario..(Ver Anexo C)

Paso N° 3 Análisis de la estacionariedad




Figura N° 09

Diferencia en 2 periodos de la Trans-logaritmo natural de la serie compra del dólar del sistema bancario, registradas por el BCRP, enero del 2004 a diciembre del 2014.

En la figura N° 09, Se observa que el comportamiento de la compra del dólar del sistema bancario enero 2004 a diciembre 2014, es estacionaria, es decir los datos se encuentran alrededor de su promedio. Para lograr cumplir con el requisito de estacionariedad que exige la metodología ARIMA de Box – Jenkins para analizar una serie, se sometió a la serie Trans logaritmicada diferenciada en dos periodos al test de Levene con la finalidad de determinar si es estacionaria.

Correlogramas de la serie transformada y diferenciada




Figura N° 10

Función de autocorrelación simple de la diferencia del logaritmo natural de la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

En la figura N° 10, se tiene las autocorrelaciones simples, la cual me permite identificar la estructura de la media del modelo compra del dólar del sistema bancario donde existen retardos significativos retardos significativos (1, 2, 7, 9 y 26) que sobresalen los límites de confianza. (Ver Anexo D).




Figura N° 11

Función de autocorrelación parcial de la diferencia del logaritmo natural de la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

En la figura N° 11, se observa que las primeras autocorrelaciones parciales descienden rápidamente a cero, apreciándose que los retardos 1, 2, 3 y 12 sobresalen los límites de confianza, por lo que se dice que existe estacionalidad en la parte autorregresiva regular. (Ver Anexo E)

Prueba de Homogeneidad de Varianzas y ANOVA Para Serie Dif_Ln_Compra (2)

Tabla N° 03

Prueba de homogeneidad de varianzas de la serie diferenciada en 2 periodos del Logaritmo Natural de la compra del dólar del sistema bancario, periodo enero 2004 a diciembre 2014.

DIFF (Trans.LN_compra,2)

	Estadístico de Levene	gl1	gl2	Sig.
DIFF (LN_compra,2)	0.782	11	118	0.657

En la tabla N° 03, se observa que el valor estadístico de levene = 0.782 y el Sig. = 0.657 > 0.05, por lo tanto se concluye que la serie diferenciada de la transformación del logaritmo natural de la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre es homocedástica. (Ver Anexo I)

Tabla N° 04

ANOVA para la diferencia en 2 periodos del Logaritmo Natural de la compra del dólar del sistema bancario, periodo enero 2004 a diciembre 2014.

	Suma de cuadrados	Gl	Media cuadrática	F	Sig.
Inter-grupos	0.002	11	0.000	0.905	0.538
Intra-grupos	0.022	118	0.000		
Total	0.024	129			

En la tabla N° 04, se aprecia el ANOVA donde el Sig. = 0.538 > 0.05, por lo tanto, se concluye estadísticamente no existe diferencias significativas entre los promedios o medias de las muestras de la diferencia del logaritmo natural de la compra del dólar en el sistema bancario. (Ver Anexo J)

Paso N°4 Estimación del modelo-compra

Modelo óptimo para la serie diferenciada en logaritmo natural de la compra del dólar en el sistema bancario

ANALISIS DEL MODELO ARIMA

Tabla N° 05

Parámetros de los modelos ARIMA, para la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 – diciembre 2014.

MODELO	COMPRA
	ARIMA(2,2,3)
R ²	0.982
RMSE	0.012
MAPE	0.743
MAE	0.008

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N° 05, se observa que el R² para el modelo es 0.98 indicando un buen coeficiente de determinación, el cual cuantifica la bondad de ajuste del modelo, el 98% respectivamente de la variación total puede ser explicado por el modelo. La RMSE es la Raíz del Error Cuadrático Promedio, mide la magnitud media del error, el RMSE para los modelos de 0.012 respectivamente. El MAPE es el Error Absoluto Porcentual Promedio, mide la desviación porcentual promedio de la serie original con los valores pronosticados, el MAPE para el modelo 0.743 respectivamente y el MAE error absoluto promedio, mide el error de los pronósticos siendo para cada modelo 0.008 respectivamente.

Tabla N° 06

Significancia de los parámetros de los modelos para las series compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

MODELO	Parámetros	Estim.	ET	T	Sig.
ARIMA (2,2,3)	Constante	-0.005	0.001	-0.066	0.948
	p	-0.919	0.067	-13.817	0.000
	d	2			
	q	0.533	0.099	5.377	0.000

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N°06, se observa los modelos ARIMA con constante que tienen una significancia de 0.151, 0.0241 y 0.948. Los coeficientes de los modelos ARIMA (2, 1,3), ARIMA (3, 1,2) y ARIMA (2, 2,3) son significativos con 0.000 respectivamente siendo este nivel de significancia menor al establecido que es de 0.05.

Paso N° 5 Validación del modelo -Compra

Tabla N° 07

Parámetros del modelo ARIMA (2,2,3) para la diferencia en dos periodos del logaritmo natural en la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

MODELO ARIMA		R ²	RMSE	MAPE	MAE
(2,2,3)		0.982	0.012	0.743	0.008
Parámetros		Estim.	ET	T	Sig.
Constante		-0.005	0.001	-0.066	0.948
AR (2)	P	-0.919	0.067	-13.817	0.000
	d	2			
MA (3)	q	0.533	0.099	5.377	0.000

Fuente: BCRP, 2017-Elaboración propia

En la tabla N° 07, se observa que el modelo ARIMA (2, 2,3) tiene un buen ajuste a los datos, siendo el coeficiente de determinación 0.982; indica que el 98.2% de la compra del dólar en el sistema bancario es explicado por el modelo. Con un error absoluto medio (RMSE) igual a 0.012 y un error absoluto promedio (MAE) igual a 0.008. Los coeficientes del modelo ARIMA son significativos ya que su probabilidad de significancia es menor que el 0.05, lo que indica que de acuerdo al criterio es adecuado.

Tabla N°08

Prueba de Kolmogorov-Smirnov para los residuos del modelo ARIMA (2, 2, 3).

Ruido residual de LN_compra-Modelo_1		
N°		130
Parámetros normales ^{a,b}	Media	-,0001
	Desviación	
	típica	,01144
Diferencias más extremas	Absoluta	,101
	Positiva	,101
	Negativa	-,087
Z de Kolmogorov-Smirnov		1,153
Sig. asintótica. (bilateral)		,140
<i>Fuente:</i> BCRP, 2017-Elaboracion propia.		

En la tabla N° 08, se observa los resultados de la prueba de Kolmogorov-Smirnov, donde el nivel de significancia de los resultados es de 0.140, por lo que se concluye estadísticamente que los errores siguen una distribución normal.

Tabla N°09

Prueba de homogeneidad de varianzas para los residuos del modelo

ARIMA (2, 2, 3)

Estadístico de Levene	gl1	gl2	Sig.
0,962	11	118	0,485

Fuente: BCRP, 2017-Elaboracion propia.

En la tabla N°09, se observa que el estadístico de Levene es 0.962 y el nivel de significancia es de $0.485 > 0.05$, se concluye estadísticamente los residuos de los pronósticos aplicando el modelo ARIMA (2,2,3) para la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014 son homocedásticos.

Tabla N° 10

ANOVA para los residuos del modelo ARIMA (2, 2, 3)

	Suma de cuadrados	g.l	Media cuadrática	F	Sig.
Inter-grupos	0.001	11	0.000		
Intra-grupos	0.016	118	0.00	0.9	0.505
Total	0.017	129			

Fuente: BCRP, 2017-Elaboracion propia

En la tabla N° 10, se observa que el nivel de significancia es de $0.505 > 0.05$ es decir estadísticamente no existen diferencias significativas entre los residuos interanuales aplicando el modelo ARIMA (2,2,3) para la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

Residuales del Modelo ARIMA (2, 2,3)-Compra




Figura N° 12

Correlograma de FAS residual y la FAP residual del modelo ARIMA (2,2,3) logaritmo natural de la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

En la figura N°12, Se puede observar los valores de los retardos de los residuales FAS y FAP; donde todos los retardos se encuentran dentro del límite de confianza del 95 %, por lo que respecto a este criterio el modelo es satisfactorio para afirmar la adecuación del modelo. ARIMA (2, 2,3) para el pronóstico del precio del dólar del sistema bancario en moneda nacional año 2015.

Paso N° 6 Pronóstico del Modelo Arima –Compra

Tabla N° 11

Pronósticos de la compra del dólar, registrados por el BCRP, para el periodo enero 2015 a diciembre 2015.

Periodo	Pronósticos	
	Valores reales compra	ARIMA (2,2,3) compra
ene-15	3.004	3.003
feb-15	3.077	3.047
mar-15	3.09	3.061
abr-15	3.118	3.088
may-15	3.149	3.109
jun-15	3.16	3.112
jul-15	3.18	3.141
ago-15	3.237	3.181
sep-15	3.217	3.191
oct-15	3.246	3.217
nov-15	3.335	3.226
dic-15	3.38	3.235

Fuente: BCRP, 2017 - Elaboración propia.

Tabla N° 11, se observa los pronóstico de la compra del dólar del sistema bancario a través de sus respectivo modelo para todo los meses de enero 2015 a diciembre 2015 y comparando con los valores reales que pronostico BCRP.




Figura N° 13

Serie pronosticada de la compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

3.3. Resultados tipo de cambio de la venta del dólar mediante la metodología de Box y Jenkins

Paso N° 1 Grafica de la serie original




Figura N° 14

Comportamiento de la venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

En la **Figura N° 14**, se observa que el comportamiento de la venta del dólar tiene una tendencia decreciente hasta diciembre del 2012, apreciándose claramente la no estacionariedad de las series, además muestran componente de tendencia y no son estacionales.

Paso N° 2 Correlograma total de la serie original




Figura N° 15

Función de autocorrelación simple de la venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

En la figura N° 15, se observa el correlograma de la función de autocorrelación simples de la venta del dólar del sistema bancario, donde los retardos descienden lentamente a cero, indicando que no son independientes. Por lo tanto, es necesario transformar la serie original.




Figura N° 16

Función de autocorrelación parcial de la venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014

En la figura N° 16, se observa la función de autocorrelación parcial descendiendo rápidamente a cero con un retardo significativo que sobresale los límites de confianza al 95%, por lo que indica que es posible que exista parte autorregresivo en el modelo de pronósticos para la venta del dólar en el sistema bancario.

Paso N° 3 Análisis de estacionariedad




Figura N° 17

Diferencia en 1 periodo del Logaritmo Natural de la Venta del dólar en el sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

En la figura N° 17, se observa que el comportamiento de la venta del dólar del sistema bancario enero 2004 a diciembre 2014, es estacionaria, es decir los datos se encuentran alrededor de su promedio. Para lograr cumplir con el requisito de estacionariedad que exige la metodología ARIMA de Box – Jenkins para analizar una serie, se sometió a la serie logaritmizada diferenciada en un periodo al test de Levene con la finalidad de determinar si es estacionaria.

Correlogramas de la serie transformada y diferenciada




Figura N° 18

Función de autocorrelación simple de 1 diferencia de la Trans-Logaritmo Natural de la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre del 2014.

En la figura N° 18, se tiene las autocorrelacion simple, la cual me permite identificar la estructura de la media del modelo venta del dólar en el sistema bancario donde existen retardos significativos (1, 7, 10 y 11) que sobresalen los límites de confianza.




Figura N° 19

Función de Función de autocorrelación parcial de 1 diferencia del Logaritmo Natural de la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

En la Figura N° 19, se observa que las autocorrelaciones Parciales, la cual me permite identificar la estructura de la media del modelo venta del dólar en el sistema bancario donde existen retardos significativos (1 y 7) que sobresalen los límites de confianza

Prueba de Homogeneidad de Varianzas y ANOVA para Serie

Dif_Trans_Ln_Venta (1)

Tabla N° 12

Prueba de homogeneidad de varianzas de la serie diferenciada de la trans-Logaritmo Natural de la venta del dólar del sistema bancario, periodo enero 2004 a diciembre 2014.

	Estadístico de Levene	gl1	gl2	Sig.
Dif_Trans_Ln_Venta	1.329	11	119	0.217

Fuente: BCRP- Elaboración

En la tabla N° 12, se observa que el valor estadístico de levene = 1.329 y el Sig. = 0.217 > 0.05, por lo tanto, se concluye que la serie diferenciada de la transformación del logaritmo natural de la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre es homocedástica.

Tabla N° 13

ANOVA para la diferencia del Logaritmo Natural de la venta del dólar del sistema bancario, periodo enero 2004 a diciembre 2014.

	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Inter- grupos	0.001	11	0.000	0.378	0.962
Intra- grupos	0.02	119	0.000		
Total	0.021	130			

En la tabla N° 13, se aprecia el ANOVA donde el Sig. = 0.962 > 0.05, por lo tanto, se concluye estadísticamente no existe diferencias significativas en por lo menos un par de medias de las muestras de la diferencia del logaritmo natural de la venta del dólar en el sistema bancario.

Paso N° 4 Estimación del modelo -Venta

Modelo óptimo para la serie diferenciada en logaritmo natural de la venta del dólar en el sistema bancario.

Tabla N° 14

Parámetros de los modelos ARIMA, para la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 – diciembre 2014.

MODELO	VENTA
	ARIMA (3,1,2)
R²	0.982
RMSE	0.012
MAPE	0.771
MAE	0.008

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N°14, se observa que el R^2 para el modelo es 0.98, indicando un buen coeficiente de determinación, el cual cuantifica la bondad de ajuste, el 98% respectivamente de la variación total puede ser explicado por el modelo. La RMSE es la Raíz del Error Cuadrático Promedio, mide la magnitud media del error, el RMSE para los modelos de 0.012. El MAPE es el Error Absoluto Porcentual Promedio, mide la desviación porcentual promedio de la serie original con los valores pronosticados, el MAPE para el modelo es 0.771. Y el MAE error absoluto promedio, mide el error de los pronósticos siendo para cada modelo 0.008 respectivamente.

Tabla N° 15

Significancia de los parámetros de los modelos para las series venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

MODELO	Parámetros	Estim.	ET	T	Sig.
ARIMA (3,1,2)	Constante	-0.003	0.003	-1.104	0.272
	p	0.415	0.084	4.939	0.000
	d	1			
	q	-0.72	0.173	-4.164	0.000

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N° 15, se observa el modelo ARIMA con constante que tienen una significancia de 0.272. Los coeficientes de los modelos ARIMA (3, 1,2) son significativos con 0.000 respectivamente siendo este nivel de significancia menor al establecido que es de 0.05.

Paso N° 5 Validación del Modelo Arima-Venta

Tabla N° 16

Parámetros del modelo ARIMA (3, 1,2) para la diferencia en un periodo del logaritmo natural en la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

MODELO	R ²	RMSE	MAPE	MAE
ARIMA (3,1,2)	0.982	0.012	0.771	0.008
Coefficiente	Estim.	ET	t	Sig.
Constante	-0.003	0.003	-1.104	0.272
AR (3) p	-0.415	0.084	4.939	0.000
d	1			
MA (2) q	-0.72	0.173	-4.164	0.000

Fuente: BCRP, 2017-Elaboracion propia.

En la tabla N° 16, se observa que el modelo ARIMA (3,1,2) tiene un buen ajuste a los datos, siendo el coeficiente de determinación 0.982; indica que el 98.2% de la venta del dólar del sistema bancario es explicado por el modelo. Con un error absoluto medio (RMSE) igual a 0.012 y un error absoluto promedio (MAE) igual a 0.008. Los coeficientes del modelo ARIMA son significativos ya que su probabilidad de significancia es menor que el 0.05, lo que indica que de acuerdo al criterio es adecuado.

Tabla N° 17

Prueba de Kolmogorov-Smirnov para los residuos del modelo ARIMA (3, 1, 2)

Ruido residual de LN_venta-Modelo_1		
N		131
	Media	,000
Parámetros normales ^{a,b}	Desviación típica	,0114
	Absoluta	,076
Diferencias más extremas	Positiva	,076
	Negativa	-,076
Z de Kolmogorov-Smirnov		,875
Sig. asintótica. (bilateral)		,429

a. La distribución de contraste es la Normal.

b. Se han calculado a partir de los datos.

Fuente: BCRP, 2017 - Elaboración propia.

En la tabla N° 17, se observa los resultados de la prueba de Kolmogorov-Smirnov, donde el nivel de significancia de los resultados es de 0.429, por lo que se concluye estadísticamente que los errores siguen una distribución normal.

Tabla N° 18

Prueba de homogeneidad de varianzas para los residuos del modelo

ARIMA (3, 1, 2).

Estadístico de Levene	gl1	gl2	Sig.
0,832	11	111	0,608

Fuente: BCRP, 2017-Elaboracion propia.

En la tabla N° 18, se observa que el estadístico de Levene es 0.832 y el nivel de significancia es de $0.608 > 0.05$, se concluye estadísticamente los residuos de los pronósticos aplicando el modelo ARIMA (3,1,2) para la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014 son homocedásticos.

Tabla N° 19

ANOVA para los residuos del modelo ARIMA (3, 1, 2).

	Suma de cuadrados	g.l	Media cuadrática	F	Sig.
Inter-grupos	0.001	11	0		
Intra-grupos	0.016	119	0	0.465	0.921
Total	0.017	130			

Fuente: BCRP, 2017-Elaboracion propia.

En la tabla N° 19, se observa que el nivel de significancia es de $0.921 > 0.05$ es decir estadísticamente no existen diferencias significativas entre los residuos interanuales aplicando el modelo ARIMA (3,1,2) para la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

Correlograma del Modelo ARIMA (3, 1, 2)-Venta.




Figura N° 20

Correlograma de FAS residual y la FAP residual del modelo ARIMA (3,1,2) logaritmo natural de la venta del dólar en el sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

En la figura N° 20, Se puede observar los valores de los retados de los residuales FAS y FAP; donde todos los retardos se encuentran dentro del límite de confianza del 95 %, lo cual evidencia para afirmar la adecuación del modelo. ARIMA (3,1,2) para el pronóstico del precio del dólar del sistema bancario en moneda nacional año 2015.

Paso N° 06 Pronósticos de los Modelos Arima -Venta

Tabla N° 20

Pronósticos de la venta del dólar, registrados por el BCRP, para el periodo enero 2015 a diciembre 2015.

Periodo	Valores reales venta	ARIMA (3,1,2) venta
ene-15	3.007	3.007
feb-15	3.08	3.068
mar-15	3.093	3.071
abr-15	3.121	3.091
may-15	3.152	3.111
jun-15	3.162	3.117
jul-15	3.183	3.145
ago-15	3.24	3.186
sep-15	3.221	3.198
oct-15	3.25	3.222
nov-15	3.339	3.229
dic-15	3.385	3.238

Fuente: BCRP, 2017 - Elaboración propia.

Tabla N° 20, se observa los pronósticos de la compra y venta del dólar en el sistema bancario a través de sus respectivos modelos para todos los meses de enero 2015 a diciembre 2015 y comparando con los valores reales que pronostico BCRP.




Figura N° 21

Serie pronosticada de la venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

3.4 Resultados tipo de cambio de la compra del dólar mediante redes neuronales artificiales.

Tabla N° 21

Modelos de redes neuronales Perceptrón Multicapa (MPL) para Pronosticar el precio del dólar del sistema bancario en moneda nacional registrados por el BCRP, periodo enero 2004 a diciembre 2014.

Modelo	Tipo de Escala de variables	Particiones	Arquitectura	Entrenamiento	Función de activación	
					Capa oculta	Capa de salida
1	Normalizada	Utilizando t	12:1:5:1	Mini lote	Tang.hiperbolica	Identidad
2	Normalizada	50:25:25	12:1:4:1	Mini lote	Tang.hiperbolica	Identidad
3	Normalizada	50:25:25	12:1:2:1	En lote	Tang.hiperbolica	Identidad
4	Normalizada	50:25:25	12:1:1:1	En línea	Tang.hiperbolica	Identidad

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N° 21, El tipo de escala de las variables predictorias o independientes, el precio del dólar del Sistema Bancario, ha sido normalizadas quedan comprendidos entre 0 y 1.

Tabla N° 22

Procesamiento de los casos de Redes neuronales Artificiales de compra dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

		N°	Porcentaje
Muestra	Entrenamiento	94	71,2%
	Prueba	38	28,8%
Válidos		132	100,0%
Excluidos		12	
Total		144	

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N° 22, se observa el resumen del procesamiento de los casos muestra que se asignaron 94 casos a la muestra de entrenamiento y 38 a la muestra reservada. Los 12 casos excluidos del análisis son posibles meses de pronosticación.

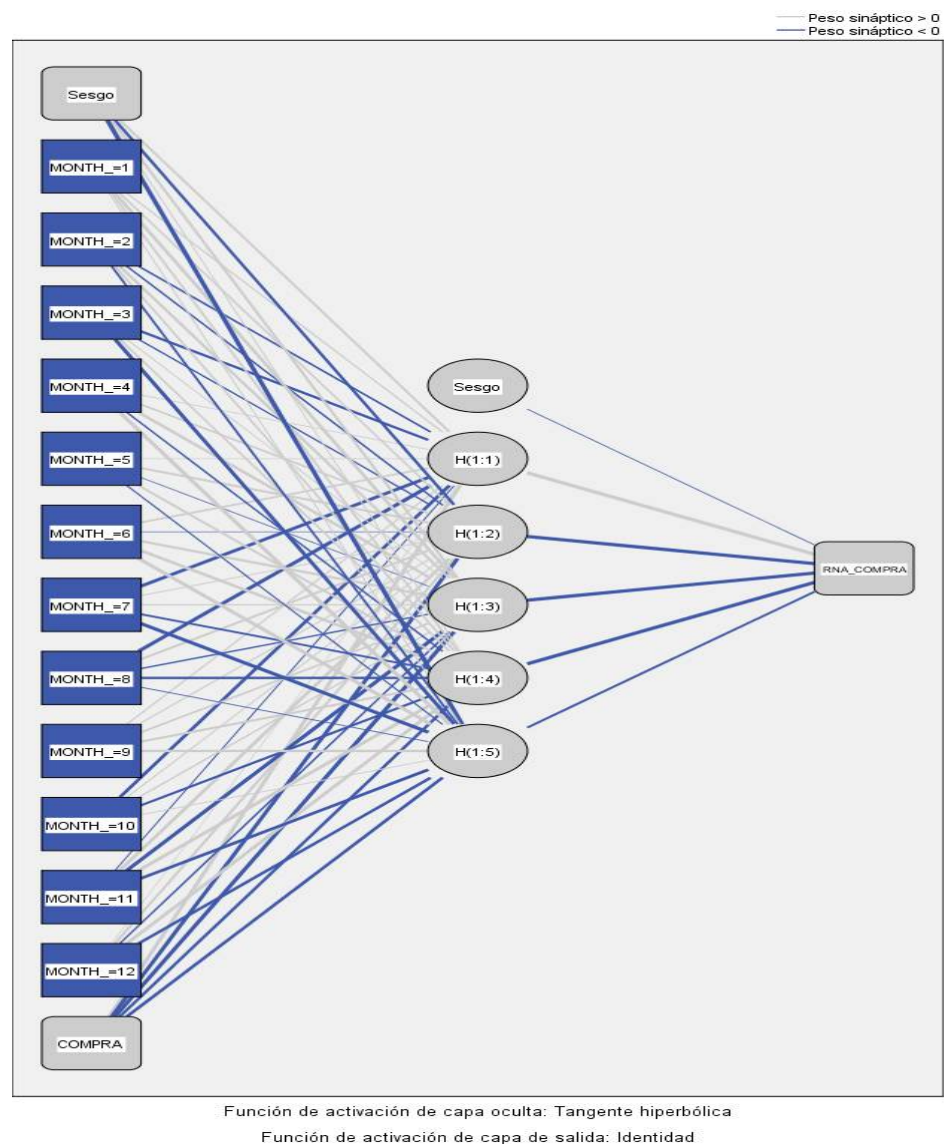


Figura N° 22

Arquitectura de Redes Neuronales Artificiales (RNA), de la compra del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Figura N° 22, Se muestra la arquitectura de RNA, con doce (12) neuronas de entrada, cinco (5) neuronas en la primera capa. Esta topología conserva el principio de parsimonia ¹ al presentar una estructura simple, es decir, una menor cantidad de parámetros.

Tabla N°23

Información sobre la red neuronal de compra dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Capa	Características	Indicadores
Entrada	Número de unidades	MESES 12
	Método de cambio de escala para las covariables	Normalizada
Ocultas	Número de capas ocultas	1
	Número de unidades de la capa oculta 1 ^a	5
	Función de activación	Tangente hiperbólica
Salida	Variables dependientes	1 Precio del Dólar COMPRA
	Número de unidades	1
	Método de cambio de escala para las dependientes de escala	Tipificados
	Función de activación	Identidad
	Función de error	Suma de cuadrados
a. Sin incluir la unidad de sesgo		

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N° 23, Se tiene las características de la estructura de la red neuronal, donde el número de unidades de capa de entrada son 12 meses consideradas de enero-diciembre, con respecto a la capa oculta es 1, la cual contiene 5 unidades o nodos, con respecto a la función de activación de la capa oculta es la tangente hiperbólica, la capa de salida se tiene la variable Precio del dólar compra y la función de activación es la Identidad.

Tabla N°24

Resumen del modelo de la red neuronal –MLP aplicado a la compra dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Proceso	Características	Indicador
Entrenamiento	Suma de errores cuadráticos	0,042
	Error relativo	0,001
	Regla de parada utilizada	1 pasos consecutivos sin disminución de errores
	Tiempo de entrenamiento	0.00:00.05
Variable dependiente	Precio del dólar del Sistema Bancario	
	Los cálculos del error se basan en la muestra del entrenamiento.	

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N°24, se tiene las características de entrenamiento de la red, la suma de errores cuadráticos de 0.042, es decir, que para la muestra se tiene un valor de la función de error de la variable dependiente, precio del dólar del sistema bancario periodo 2004-2014. El error relativo se refiere al error de la diferencia entre el valor original menos el valor pronosticado con la red, el valor relativo es 0.00 todos los valores de los errores están expresados en la escala numérica normalizada. La regla de parada utilizada en 1 pasos consecutivos sin disminución de error, es decir, que el algoritmo de entrenamiento finaliza cuando encuentre el menor error dentro de todas las iteraciones realizadas, por lo tanto, no necesita disminuir el error en cada iteración. El tiempo de entrenamiento es de 0.00:00:05. Es el tiempo utilizado para entrenar el modelo.

Tabla N° 25

Estimación de los parámetros del modelo de la red neuronal –MPL, aplicado a la compra dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Pronosticado						
Predictor	Capa oculta 1					capa de salida
	H(1:1))	H(1:2)	H(1:3)	H(1:4)	H(1:5)	compra del dólar del sistema bancario
Capa de entrada	(Sesgo)	,093	-,470	,218	,052	-,543
	[MONTH_=1]	,088	,120	,333	,142	,058
	[MONTH_=2]	-,141	-,103	,237	,141	-,143
	[MONTH_=3]	-,250	-,094	,049	,135	-,358
	[MONTH_=4]	,028	,172	,329	-,101	,403
	[MONTH_=5]	,013	,226	-,016	,205	-,068
	[MONTH_=6]	,189	-,007	,267	,352	,403
	[MONTH_=7]	-,388	,063	,080	-,202	-,451
	[MONTH_=8]	-,448	,210	-,095	-,328	-,027
	[MONTH_=9]	,092	,070	,181	,233	,303
	[MONTH_=10]	-,342	,063	,099	-,236	,034
	[MONTH_=11]	-,054	,340	-,409	,387	-,354
	[MONTH_=12]	,003	,210	-,116	,356	-,332
Capa oculta 1	COMPRA	,353	-,369	-,407	-,324	-,337
	(Sesgo)					0,021
	H(1:1)					0,990
	H(1:2)					-0,679
	H(1:3)					-,593
	H(1:4)					-0,716
	H(1:5)					-0,207

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla 25, se tiene las ponderaciones sinápticas del modelo de la red neuronal para cada una de las covariables que son 12, las ponderaciones son una para cada nodo de la capa oculta; cada nodo también tiene una ponderación sináptica. Por otro lado, también se aprecia un sesgo tanto para las variables predictoras o covariables, así como también en la capa oculta, esto indica que el momento de realzar los pronósticos el sesgo corrige errores de manera que no sean muy elevados y pueden invalidar el modelo.

3.5. Resultados tipo de cambio de la venta del dólar mediante redes neuronales artificiales.

Tabla N° 26

Modelos de redes neuronales Perceptrón Multicapa (MPL) para Pronosticar el precio de venta del dólar del sistema bancario en moneda nacional registrados por el BCRP, periodo enero 2004 a diciembre 2014.

Modelo	Tipo De Escala de variables	Particiones	Arquitectura	Entrenamiento	Función de activación	
					Capa oculta	Capa de salida
1	Normalizada	Utilizando t	12:1:6:1	Mini lote	Tang.hiperbolica	Identidad
2	Normalizada		12:1:5:1	Mini lote	Tang.hiperbolica	Identidad
3	Normalizada		12:1:2:1	En lote	Tang.hiperbolica	Identidad
4	Normalizada		12:1:2:1	En línea	Tang.hiperbolica	Identidad

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N° 26, el tipo de escala de las variables predictorias o independientes, el precio venta del dólar del sistema bancario, ha sido normalizadas quedan comprendidos entre 0 y 1.

Tabla N° 27

Procesamiento de los casos de Redes neuronal de venta dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Procesamiento de los casos		N	Porcentaje
Muestra	Entrenamiento	95	66,2%
	Prueba	35	33,8%
Válidos		132	100,0%
Excluidos		12	
Total		144	

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N° 27, se observa el resumen del procesamiento de los casos muestra que se asignaron 95 casos a la muestra de entrenamiento y 35 a la muestra reservada. Los 12 casos excluidos del análisis son posibles meses de pronóstico.

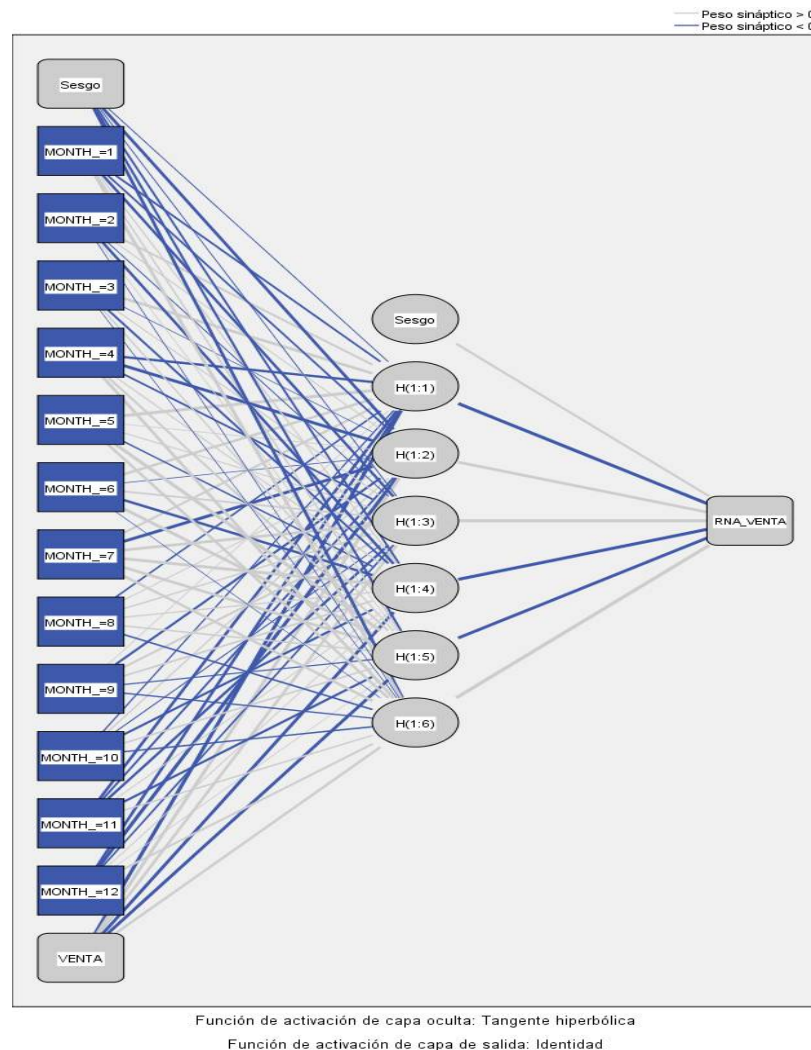


Figura N° 23

Arquitectura de Redes Neuronales Artificiales (RNA), de la venta del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

En la figura N°23, se muestra la arquitectura de RNA, con doce (12) neuronas de entrada, cinco (6) neuronas en la primera capa. Esta topología conserva el principio de parsimonia ¹ al presentar una estructura simple, es decir, una menor cantidad de parámetros.

Tabla N° 28

Información sobre la red neuronal de venta dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Capa	Características	Indicadores
Capa de entrada	Número de unidades ^a	MESES 12
	Método de cambio de escala de las covariables	Normalizada
	Número de capas ocultas	1
Capas ocultas	Número de unidades de la capa oculta 1 ^a	6
	Función de activación	Tangente hiperbólica
Capa de salida	Variables dependientes 1	Venta del dólar del sistema bancario
	Número de unidades	1
	Método de cambio de escala para dependientes de escala	Tipificados
	Función de activación	Identidad
	Función de error	Suma de cuadrados

a. Sin incluir la unidad de sesgo

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N° 28, se tiene las características de la estructura de la red neuronal, donde el número de unidades de capa de entrada son 12 meses consideradas de enero-diciembre, con respecto a la capa oculta es 1, la cual contiene 6 unidades o nodos, con respecto a la función de activación de la capa oculta es la tangente hiperbólica, la capa de salida se tiene la variable Precio del dólar venta y la función de activación es la Identidad.

Tabla N° 29

Resumen del modelo de la red neuronal –MLP aplicado a la venta del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Proceso	Características	Indicar
Entrenamiento	Suma de errores cuadráticos	0,039
	Error relativo	0,001
	Regla de parada utilizada	1 pasos consecutivos sin disminución de errores
	Tiempo de entrenamiento	0:00.00.03
Variable dependiente	Precio del dólar del Sistema Bancario	
	Los cálculos del error se basan en la muestra del entrenamiento.	

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N°29, la tabla de resumen del modelo despliega información sobre los resultados de entrenamiento y de reserva. El error relativo es desplegado porque la capa resultados utiliza la activación identidad. Se tiene las características de entrenamiento de la red la suma de errores cuadráticos de 0.039, es decir, es decir que para muestra se tiene un valor de la función de error de la variable dependiente, precio del dólar del sistema bancario periodo 2004-2014. El error relativo se refiere al error de la diferencia entre el valor original menos el valor pronosticado con la red, el valor relativo es 0.00 todos los valores de los errores están expresados en la escala numérica normalizada. La regla de parada utilizada en 1 paso consecutivos sin disminución de error, es decir, que el logaritmo de entrenamiento finaliza cuando encuentre el menor error dentro de todas las iteraciones realizadas, por lo tanto, no necesita disminuir el error en cada iteración. El tiempo de entrenamiento es de 0:00:03. Es el tiempo utilizado para entrenar el modelo.

Tabla N° 30

Estimación de los parámetros del modelo de la red neuronal –MPL, aplicado a la venta del dólar del sistema bancario en moneda nacional, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

		Pronosticado					
Predictor		Capa oculta 1					capa de salida
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)
Capa	(Sesgo)	-,052	-,309	-,044	-,163	-,198	-,286
	[MONTH_=1]	-,167	-,148	-,240	,094	,117	,325
	[MONTH_=2]	,223	,073	-,053	-,247	,018	-,015
	[MONTH_=3]	,355	-,004	,089	-,185	,109	-,010
	[MONTH_=4]	-,286	-,396	-,184	,100	,196	,325
	[MONTH_=5]	,528	,052	,090	-,121	,499	,263
	[MONTH_=6]	,319	-,021	,193	-,290	,434	-,001
	[MONTH_=7]	,234	-,440	,365	,496	,329	,273
	[MONTH_=8]	-,134	,072	,122	,110	,147	-,143
	[MONTH_=9]	,031	-,231	,225	,187	-,096	-,111
	[MONTH_=10]	-,097	,103	-,071	-,234	,147	-,126
	[MONTH_=11]	-,270	-,171	-,238	,071	-,238	,130
	[MONTH_=12]	-,255	-,376	-,141	,069	,022	,209
	VENTA	-,373	,328	,260	-,328	-,344	,242
	(Sesgo)						,232
Capa oculta 1	H(1:1)						-,504
	H(1:2)						,360
	H(1:3)						1,034
	H(1:4)						-,559
	H(1:5)						-,377
	H(1:6)						,911

Fuente: BCRP, 2017 - Elaboración propia.

En la Tabla N° 30, se tiene las ponderaciones sinápticas del modelo de la red neuronal para cada una de las covariables que son 12, las ponderaciones son una para cada nodo de la capa oculta; cada nodo también tiene una ponderación sináptica. Por otro lado, también se aprecia un sesgo tanto para las variables predictoras o covariables, así como también en la capa oculta, esto indica que el momento de realzar los pronósticos el sesgo corrige errores de manera que no sean muy elevados y pueden invalidar el modelo.

3.5.1. Pronóstico de Redes Neuronales Artificiales Compra y Venta dólar

Tabla N° 31

Pronósticos de la compra y venta del dólar del sistema bancario en moneda nacional para el periodo enero a diciembre 2015, con el modelo de redes neuronales – Perceptrón Multicapa.

Multicapa.

Pronósticos				
Periodo	Valores reales compra	Pronostico RNA-MLP compra 12:1:5:1	Valores reales venta	Pronostico RNA-MLP venta 12:1:6:1
ene-15	3.004	2.9258	3.007	3.0056
feb-15	3.077	2.9335	3.080	3.0206
mar-15	3.090	2.9314	3.093	3.0437
abr-15	3.118	2.9345	3.121	3.0506
may-15	3.149	2.924	3.152	3.0505
jun-15	3.160	2.9106	3.162	3.0505
jul-15	3.180	2.8999	3.183	3.0505
ago-15	3.237	2.8961	3.240	3.0505
sep-15	3.217	2.8947	3.221	3.0505
oct-15	3.246	2.8942	3.250	3.0505
nov-15	3.335	2.894	3.339	3.0506
dic-15	3.380	2.8939	3.385	3.0505

Fuente: BCRP, 2017 - Elaboración propia.

3.6 Comparación de los modelos de RNA y Box y Jenkins

Tabla N° 32

Comparación de los modelos de redes Neuronales Artificiales y Box y Jenkins.

Característica	MODELO			
	RNA-MLP		ARIMA	
	12:1:5:1	12:1:6:1	ARIMA(2,2,3)	ARIMA(3,1,0)
	COMPRA	VENTA	COMPRA	VENTA
RMSE	0.042	0.038	0.012	0.012
MAPE	0.579	0.565	0.743	0.771
MAE	0.004	0.043	0.008	0.008

Fuente: BCRP, 2017 - Elaboración propia.

La raíz error del cuadrático promedio (RMSE) que se muestra en la **tabla N° 32**. Medida de cuanto se desvía la serie dependiente del nivel pronosticado, para el modelo de RNA –MLP para la compra es 0.042 en dólares y para la venta 0.038 y para el modelo ARIMA (2,2,3) compra y para el modelo ARIMA (3,1,2) venta es de 0.012, el cual es menor que el modelo de red. El MAPE , error absoluto porcentual promedio, también mide la desviación de la serie dependiente del nivel pronosticado por el modelo, para este caso para redes neuronales es de 0.579 para la compra y 0.565 para venta y para el modelo ARIMA (2,2,3) es de 0.743 para la compra y 0.771 para la venta. Finalmente se tiene el MAE, error absoluto promedio. Mide la desviación de la serie a nivel pronosticado por el modelo, para RNA-compra es de 0.004 y 0.043 para la venta y para el modelo ARIMA (2,2,3)-compra y para el modelo ARIMA (3,1,2) VENTA es de 0.008 en dólares, siendo este último mucho mejor que el modelo de redes neuronales artificiales.

CAPITULO IV

CONCLUSIONES Y SUGERENCIAS

CONCLUSIONES

- Los resultados predictivos para el precio del dólar del sistema bancario periodo de enero 2004 a diciembre 2014; presentan la componente de tendencia estacionaria, es decir que sus datos se encuentran alrededor de su promedio (ver figura 09).
- El precio del dólar en moneda nacional del sistema bancario año 2015. Ha mostrado un comportamiento aceptable, es decir más acentuado en los meses de enero hasta diciembre acercándose a la realidad pronosticada por el Banco Central de Reservas del Perú.

Modelo	Ene 2015	Feb 2015	Mar 2015	Abr 2015	May 2015	Jun 2015	Jul 2015	Ago 2015	Sep 2015	Oct 2015	Nov 2015	Dic 2015
COMPRA-Modelo_1	3.003	3.047	3.061	3.088	3.109	3.112	3.141	3.181	3.191	3.217	3.226	3.235
VENTA-Modelo_1	3.007	3.068	3.071	3.091	3.111	3.117	3.145	3.186	3.198	3.222	3.229	3.238

- El modelo estimado mediante la metodología de Box y Jenkins, de la compra y venta del dólar en moneda nacional de enero a diciembre para el año 2015, es un modelo ARIMA (2, 2,3) para la compra y ARIMA (3, 1,2) para la venta. (ver tabla 7 y tabla 15).
- Mediante la metodología de redes neuronales artificiales de la compra y venta en moneda nacional de enero a diciembre para el año 2015 el modelo es de (12:1:5:1) con RMSE 0.042 (ver tabla 22); 12 son las covariables; es decir los meses de enero a diciembre de cada año; 1 capa oculta; 5 nodos en la capa oculta y 1 capa de salida para la compra y para la venta con un modelo (12:1:6:1) RMSE 0.038 (ver tabla 27); 12 son las covariables; es decir los

meses de enero a diciembre de cada año; 1 capa oculta; 6 nodos en la capa oculta y 1 capa de salida.

- Mediante redes neuronales artificiales y la metodología de Box y Jenkins se ha estimado cuatro modelos, al comparar sus errores de estos modelos (Tabla N° 31), Se llega a la conclusión que el modelo de Box y Jenkins es más factible, tiene un menor error absoluto (MAE) para el modelo ARIMA (2,2,3) compra y para el modelo ARIMA (3,1,2) venta es de 0.008,
- El mejor modelo en serie de tiempo que nos permite describir y predecir el precio del dólar es el modelo siguiente:

Parámetros del modelo ARIMA (2, 2,3) compra.

$$Y_t = -0.005 + 0.240Y_{t-1} - 0.919Y_{t-2} + 0.008 - 0.790e_{t-1} + 0.906e_{t-2} - 0.533e_{t-3}$$

Parámetros del modelo ARIMA (3, 1,2) venta

$$Y_t = -0.003 + 1.023Y_{t-1} - 1.043Y_{t-2} + 0.415Y_{t-3} - 0.008 - 0.675e_{t-1} + 0.720e_{t-2}.$$

SUGERENCIAS

- Ampliar un buen estudio de la Metodología de Box y Jenkins aplicado al tipo de cambio del dólar del sistema bancario en moneda nacional año 2015, para tener en cuenta como pronosticar a futuro y estar listo para proponer proyectos.
- Se sugiere al sistema del Banco Central de Reservas del Perú, que se tenga en cuenta estos pronósticos, ya que serán de gran ayuda para su toma de decisiones para diseñar un plan estratégico con una nueva metodología fácil de aprender y manejar.
- Se sugiere a su área de sistema bancario del Banco Central de Reservas del Perú, tener en cuenta en sus plataformas virtuales estos pronósticos para ser publicados a los sistemas bancarios correspondientes del BCRP, para que tengan acceso a observar cómo se obtuvo el pronóstico del dólar de enero a diciembre del año 2015.
- Se sugiere a los Profesionales en Estadística hacer uso de estas metodologías explicadas anteriormente para proyectos de investigación a futuro, que será de una gran ayuda y satisfacción en sus áreas correspondientes.

REFERENCIA BIBLIOGRAFICAS

- Banco Central de Reservas del Perú (2014), [En línea] Fecha de consulta 20 de Febrero 2017 <http://www.bcrp.gob.pe/sobre-el-bcrp/preguntas-frecuentes.html>
- Banco Central de Reservas del Perú (2017),[En Línea], Fecha de Consulta: 12 de marzo del 2017].Base de datos disponible en <http://www.bcrp.gob.pe>
- Banco Central de Reservas del Perú” [En línea] Fecha de consulta20 de Febrero 2017 <http://www.bcrp.gob.pe/sobre-el-bcrp/preguntas-frecuentes.html>
- Barrera, C. (2010). Redes neuronales para predecir el tipo de cambio diario (Trabajo de Investigación). Banco Central De Reservas Del Perú, Lima-Perú.
- Benedetti, F, Baiguna, A, y Yanguas. M (2009). *Predicciones de Series de Tiempo con Redes Neuronales: Trading usando el Índice Merval*. (Trabajo de Investigación). Universidad de Argentina. Recuperado de <http://www.elautomataeconomico.com.ar/download/TP-2011/Benedetti-Baigun-Yanguas.pdf>.
- Bowerman, B. L.; O`Connell, R. T. y Koehler, A. B. (2007). *Pronósticos, series de tiempo y regresión*. México: Torzón. Pág. 11.
- Box, G. E. P., Jenkins, G. M, Reinsel, G. C. (2008). *Time Series Analysis: Forecasting and Control*, 4th ed., John Wiley & Sons, Inc.EEUU
- Cárdenas, J. (2015). *Pronósticos y comparación de una serie de tiempo con cambios estructurales mediante la red neuronal artificial de retropropagación resiliente y modelos no lineales*. (Tesis para optar Título en Estadística). Universidad Nacional Mayor de San Marcos, Lima-Perú.
- Castillo, J. (2015). *Concepto de red neuronal con especial atención al Percepción Multicapa como elemento clasificador de patrones*. [En línea].2017 Editorial, Periódico El Comercio [Fecha de consulta: 22 de enero]

- Federal Reserve Systeml (2017), [En línea] Fecha de consulta 20 de Febrero 2017
- Gujarati, D y Ponter, D. (2010), *Econometrical*. (5ª ed.). Mexico: McGRAW-HILL
- Hanke, J. y Reits, A. (2014), “Pronósticos en los Negocios”, (5ª ed.). México: PEARSON
- Hernández, R. Collado, F. y Baptista, L (2010). *Metodología de la Investigación*, Editorial México: McGraw-Hill.
- Khashei, M. Y Bijari, M. (2011). *A novel hybridization of artificial neural networks and ARIMA models for time series forecasting*, Appl. Soft Comput., vol. 11, no. 2, pp. 2664–2675, Mar. 2011.
- Makridakis, S. y Wheelwright, S. (2010). *Métodos de Pronósticos*, Limusa S.A., México.
- Morales A. (2008). *Pronósticos mediante redes neuronales artificiales y modelos arima: el caso de los cetes en México*, UNAM, 794pp
- Panahian, H. (2001). *Stock price prediction by artificial neural networks*; Economic &management; I.A.U;47.
- Suclupe, M y Uriarte, Y (2014). *Estrategias metodológicas para el pronóstico del tipo de cambio del dólar americano Perú 2009-2014*, (Tesis para optar Titulo en Estadística), Universidad Nacional Pedro Ruiz Gallo, Lima-Perú.
- Superintendencia de Banca y Seguros del Perú (2017), [En línea] Fecha de consulta 20 de Febrero 2017 Datos disponibles en <https://www.sbs.gob.pe/>
- Torres, L. y Munnguia, A. (2016). *Contraste entre modelos de Redes Neuronales Artificiales, GLM y GARCH en el pronóstico y análisis del tipo de cambio mexicano: 2000-2014* (Tesis para optar Titulo en Economía). Universidad Autónoma del Estado De México. Recuperado de <http://hdl.handle.net/20.500.11799/64256>

Valencia, J. (2016). *Pronóstico de Series de Tiempo con ciclo y tendencia usando Redes Neuronales Artificiales* (Tesis Maestría). Universidad Nacional de Colombia.

Velarde, J. (2016), *Gestión de Mercados ante una fuerte demanda*.

Zapata, L. y Diaz, H. (2008). *Predicción del tipo de cambio peso-dólar utilizando redes neuronales artificiales*. (Tesis Doctoral). Universidad Fundación del Norte, Barranquilla, Colombia. Recuperado de <http://rcientificas.uninorte.edu.com>

ANEXOS

ANEXO A

Series de la compra y venta del dólar del sistema bancario, registrado por el BCRP, periodo enero 2004 a diciembre 2014.

MES	PRECIO DÓLAR -COMPRA										
	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014
ENERO	3.467	3.267	3.392	3.192	2.95	3.151	2.854	2.786	2.692	2.551	2.809
FEBRERO	3.483	3.258	3.288	3.19	2.906	3.235	2.853	2.77	2.683	2.578	2.812
MARZO	3.464	3.258	3.338	3.185	2.814	3.174	2.838	2.779	2.67	2.593	2.806
ABRIL	3.469	3.257	3.33	3.178	2.746	3.084	2.84	2.815	2.656	2.597	2.794
MAYO	3.486	3.254	3.278	3.167	2.804	2.994	2.845	2.774	2.669	2.645	2.786
JUNIO	3.476	3.252	3.264	3.17	2.89	2.988	2.837	2.763	2.671	2.748	2.794
JULIO	3.441	3.251	3.243	3.16	2.848	3.012	2.823	2.741	2.634	2.776	2.786
AGOSTO	3.395	3.257	3.234	3.158	2.895	2.95	2.802	2.739	2.615	2.801	2.814
SEPTIEMBRE	3.357	3.307	3.247	3.136	2.965	2.909	2.79	2.744	2.602	2.777	2.864
OCTUBRE	3.322	3.38	3.237	3.019	3.073	2.871	2.791	2.731	2.587	2.768	2.906
NOVIEMBRE	3.309	3.375	3.222	3	3.092	2.883	2.805	2.704	2.598	2.798	2.923
DICIEMBRE	3.281	3.423	3.205	2.981	3.113	2.877	2.815	2.696	2.566	2.785	2.986

MES	PRECIO DÓLAR -VENTA										
	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014
ENERO	3.468	3.269	3.394	3.193	2.952	3.152	2.86	2.788	2.693	2.565	2.825
FEBRERO	3.484	3.26	3.29	3.191	2.908	3.237	2.855	2.771	2.684	2.586	2.813
MARZO	3.466	3.26	3.339	3.186	2.816	3.175	2.84	2.801	2.672	2.595	2.813
ABRIL	3.47	3.259	3.333	3.179	2.749	3.086	2.841	2.828	2.658	2.636	2.802
MAYO	3.488	3.256	3.28	3.168	2.805	2.995	2.846	2.776	2.703	2.726	2.788
JUNIO	3.478	3.253	3.265	3.171	2.893	2.989	2.838	2.765	2.672	2.795	2.795
JULIO	3.443	3.253	3.244	3.161	2.849	3.013	2.824	2.743	2.636	2.788	2.793
AGOSTO	3.396	3.258	3.235	3.159	2.897	2.951	2.803	2.74	2.617	2.82	2.837
SEPTIEMBRE	3.358	3.308	3.249	3.137	2.967	2.91	2.791	2.766	2.603	2.78	2.901
OCTUBRE	3.324	3.382	3.238	3.02	3.077	2.873	2.792	2.732	2.59	2.77	2.925
NOVIEMBRE	3.311	3.377	3.223	3.002	3.094	2.886	2.806	2.706	2.599	2.807	2.926
DICIEMBRE	3.283	3.425	3.206	2.982	3.115	2.878	2.816	2.698	2.568	2.802	2.99

ANEXO B

Función de autocorrelación compra (AFC) del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014 de la serie original.

Autocorrelaciones					
Serie: COMPRA					
Retardo	Autocorrección	Típ. Error ^a	Estadístico de Box-Ljung		
			Valor	gl	Sig. ^b
1	,977	,086	128,919	1	,000
2	,946	,086	250,780	2	,000
3	,915	,085	365,632	3	,000
4	,881	,085	472,934	4	,000
5	,843	,085	571,851	5	,000
6	,802	,084	662,097	6	,000
7	,764	,084	744,666	7	,000
8	,734	,084	821,466	8	,000
9	,709	,083	893,723	9	,000
10	,686	,083	961,975	10	,000
11	,668	,083	1,027,119	11	,000
12	,655	,082	1,090,305	12	,000
13	,646	,082	1,152,251	13	,000
14	,636	,082	1,212,968	14	,000
15	,626	,081	1,272,258	15	,000
16	,616	,081	1,330,122	16	,000
17	,605	,081	1,386,481	17	,000
18	,591	,080	1,440,698	18	,000
19	,574	,080	1,492,244	19	,000
20	,555	,080	1,540,855	20	,000
21	,531	,079	1,585,741	21	,000
22	,502	,079	1,626,184	22	,000
23	,471	,079	1,662,230	23	,000
24	,438	,078	1,693,646	24	,000
25	,408	,078	1,721,186	25	,000
26	,385	,077	1,745,868	26	,000
27	,356	,077	1,767,248	27	,000
28	,329	,077	1,785,673	28	,000
29	,307	,076	1,801,886	29	,000
30	,286	,076	1,816,109	30	,000
31	,266	,076	1,828,523	31	,000
32	,247	,075	1,839,305	32	,000
33	,228	,075	1,848,557	33	,000
34	,209	,074	1,856,444	34	,000
35	,189	,074	1,862,931	35	,000
36	,167	,074	1,868,058	36	,000

a. El proceso subyacente asumido es la independencia (ruido blanco).

b. Basado en la aproximación chi cuadrado asintótica.

ANEXO C

Función autocorrelación parcial estimada compra (ACFP) del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014 de la serie original.

Autocorrelaciones parciales

Serie: COMPRA

Retardo	Autocorrela	Típ. Error
1	,977	,087
2	-,186	,087
3	,005	,087
4	-,084	,087
5	-,097	,087
6	-,051	,087
7	,063	,087
8	,143	,087
9	,066	,087
10	,009	,087
11	,045	,087
12	,052	,087
13	,015	,087
14	-,026	,087
15	-,021	,087
16	-,002	,087
17	-,014	,087
18	-,055	,087
19	-,015	,087
20	-,008	,087
21	-,108	,087
22	-,088	,087
23	,007	,087
24	-,082	,087
25	,092	,087
26	,109	,087
27	-,175	,087
28	,010	,087
29	,019	,087
30	-,079	,087
31	-,010	,087
32	,009	,087
33	-,027	,087
34	-,024	,087
35	-,063	,087
36	,003	,087

ANEXO D

Funciones de autocorrelación de la 2 Dif_ Ln_compra (AFC) del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre a 2014.

Autocorrelaciones					
Serie: DIFF(LN_compra,2)					
Retardo	Autocorrelación	Típ. Error ^a	Estadístico de Box-Ljung		
			Valor	gl	Sig. ^b
1	-,257	,087	8,778	1	,003
2	-,293	,086	20,279	2	,000
3	-,006	,086	20,284	3	,000
4	,083	,086	21,225	4	,000
5	,169	,085	25,147	5	,000
6	-,024	,085	25,224	6	,000
7	-,246	,085	33,699	7	,000
8	-,032	,084	33,843	8	,000
9	,253	,084	42,911	9	,000
10	-,103	,084	44,424	10	,000
11	-,106	,083	46,035	11	,000
12	-,069	,083	46,725	12	,000
13	,103	,083	48,279	13	,000
14	,087	,082	49,393	14	,000
15	-,062	,082	49,969	15	,000
16	-,116	,082	51,989	16	,000
17	,137	,081	54,838	17	,000
18	,025	,081	54,934	18	,000
19	-,077	,080	55,856	19	,000
20	,072	,080	56,669	20	,000
21	-,035	,080	56,866	21	,000
22	,025	,079	56,965	22	,000
23	,079	,079	57,979	23	,000
24	-,128	,079	60,639	24	,000
25	-,093	,078	62,042	25	,000
26	,244	,078	71,894	26	,000
27	-,049	,077	72,295	27	,000
28	-,151	,077	76,133	28	,000
29	,057	,077	76,683	29	,000
30	,050	,076	77,111	30	,000
31	-,009	,076	77,126	31	,000
32	-,033	,076	77,312	32	,000
33	-,103	,075	79,180	33	,000
34	,140	,075	82,669	34	,000
35	,049	,074	83,105	35	,000
36	-,075	,074	84,120	36	,000

a. El proceso subyacente asumido es la independencia (ruido blanco).

b. Basado en la aproximación chi cuadrado asintótica.

El $p < 0.05$, por lo que se concluye con un 95% de confianza que las funciones de autocorrelaciones de los retardos no son independientes

ANEXO E

Función de Autocorrelacion parcial estimada de la 2Dif_Ln_Compra (AFCP) del dólar del sistema bancario, registrados por el BCRP, periodo enero2004 a diciembre 2014.

Autocorrelaciones parciales
Serie: DIFF(LN_compra,2)

Retardo	Autocorrelación parcial	Típ. Error
1	-,257	,088
2	-,384	,088
3	-,262	,088
4	-,171	,088
5	,089	,088
6	,121	,088
7	-,108	,088
8	-,171	,088
9	,037	,088
10	-,148	,088
11	-,139	,088
12	-,201	,088
13	-,078	,088
14	-,072	,088
15	-,070	,088
16	-,099	,088
17	,070	,088
18	-,059	,088
19	-,127	,088
20	,012	,088
21	-,007	,088
22	-,037	,088
23	,061	,088
24	-,033	,088
25	-,150	,088
26	,073	,088
27	,042	,088
28	-,063	,088
29	,020	,088
30	,096	,088
31	-,011	,088
32	-,069	,088
33	-,092	,088
34	,104	,088
35	-,016	,088
36	,014	,088

ANEXO F

Funciones de autocorrelación de la Venta (AFC) del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Autocorrelaciones					
Serie: VENTA					
Retardo	Autocorrelación	Típ. Error ^a	Estadístico de Box-Ljung		
			Valor	gl	Sig. ^b
1	,976	,086	128,693	1	,000
2	,945	,086	250,115	2	,000
3	,913	,085	364,366	3	,000
4	,878	,085	470,889	4	,000
5	,839	,085	568,948	5	,000
6	,798	,084	658,296	6	,000
7	,759	,084	739,868	7	,000
8	,729	,084	815,682	8	,000
9	,704	,083	886,980	9	,000
10	,681	,083	954,256	10	,000
11	,663	,083	1,018,449	11	,000
12	,650	,082	1,080,739	12	,000
13	,641	,082	1,141,903	13	,000
14	,632	,082	1,201,866	14	,000
15	,623	,081	1,260,462	15	,000
16	,613	,081	1,317,679	16	,000
17	,602	,081	1,373,426	17	,000
18	,588	,080	1,427,108	18	,000
19	,572	,080	1,478,262	19	,000
20	,553	,080	1,526,590	20	,000
21	,529	,079	1,571,179	21	,000
22	,500	,079	1,611,313	22	,000
23	,469	,079	1,647,076	23	,000
24	,436	,078	1,678,249	24	,000
25	,407	,078	1,705,631	25	,000
26	,383	,077	1,730,171	26	,000
27	,355	,077	1,751,367	27	,000
28	,328	,077	1,769,614	28	,000
29	,306	,076	1,785,664	29	,000
30	,284	,076	1,799,691	30	,000
31	,264	,076	1,811,889	31	,000
32	,244	,075	1,822,419	32	,000
33	,225	,075	1,831,428	33	,000
34	,206	,074	1,839,089	34	,000
35	,185	,074	1,845,349	35	,000
36	,163	,074	1,850,262	36	,000

a. El proceso subyacente asumido es la independencia (ruido blanco).

b. Basado en la aproximación chi cuadrado asintótica.

ANEXO G

Autocorrelación parcial estimada de la Venta (ACFP) del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Autocorrelaciones parciales Serie: VENTA

Retardo	Autocorrelación parcial	Típ. Error
1	,976	,087
2	-,180	,087
3	,006	,087
4	-,086	,087
5	-,086	,087
6	-,051	,087
7	,052	,087
8	,150	,087
9	,061	,087
10	,005	,087
11	,051	,087
12	,054	,087
13	,024	,087
14	-,038	,087
15	-,011	,087
16	-,006	,087
17	-,015	,087
18	-,047	,087
19	-,005	,087
20	-,011	,087
21	-,121	,087
22	-,085	,087
23	,010	,087
24	-,076	,087
25	,097	,087
26	,093	,087
27	-,174	,087
28	,009	,087
29	,017	,087
30	-,076	,087
31	-,009	,087
32	-,003	,087
33	-,011	,087
34	-,030	,087
35	-,068	,087
36	,010	,087

ANEXO H

Funciones de autocorrelación de la Dif_Ln de la venta (AFC) del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Autocorrelaciones
Serie: DIFF(LN_VENTA,1)

Retard o	Autocor relación	Típ. Error ^a	Estadístico de Box-Ljung		
			Valor	gl	Sig. ^b
1	0.331	0.086	14.677	1	,000
2	0.049	0.086	15.001	2	,001
3	0.12	0.086	16.976	3	,001
4	0.14	0.085	19.663	4	,001
5	0.127	0.085	21.905	5	,001
6	-0.054	0.085	22.313	6	,001
7	-0.285	0.084	33.695	7	,000
8	-0.164	0.084	37.507	8	,000
9	-0.011	0.084	37.524	9	,000
10	-0.189	0.083	42.691	10	,000
11	-0.224	0.083	49.957	11	,000
12	-0.16	0.083	53.714	12	,000
13	0.049	0.082	54.067	13	,000
14	0.044	0.082	54.362	14	,000
15	0.002	0.082	54.363	15	,000
16	0.025	0.081	54.46	16	,000
17	0.149	0.081	57.864	17	,000
18	0.114	0.081	59.87	18	,000
19	0.066	0.08	60.553	19	,000
20	0.119	0.08	62.759	20	,000
21	0.035	0.079	62.957	21	,000
22	0.027	0.079	63.072	22	,000
23	-0.004	0.079	63.074	23	,000
24	-0.12	0.078	65.415	24	,000
25	-0.02	0.078	65.477	25	,000
26	0.109	0.078	67.443	26	,000
27	-0.074	0.077	68.353	27	,000
28	-0.126	0.077	71.043	28	,000
29	0.003	0.077	71.044	29	,000
30	0.009	0.076	71.06	30	,000
31	-0.012	0.076	71.087	31	,000
32	-0.075	0.075	72.083	32	,000
33	-0.035	0.075	72.297	33	,000
34	0.126	0.075	75.137	34	,000
35	0.08	0.074	76.295	35	,000
36	-0.01	0.074	76.312	36	,000

a. El proceso subyacente asumido es la independencia (ruido blanco).

b. Basado en la aproximación chi cuadrado asintótica.

ANEXO I

Función autocorrelación parcial estimada Dif_Ln de la Venta (ACFP) del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre del 2014.

Autocorrelaciones parciales		
Serie: DIFF(LN_VENTA,1)		
Retardo	Autocorrelación parcial	Típ. Error
1	0.331	0.087
2	-0.068	0.087
3	0.142	0.087
4	0.063	0.087
5	0.074	0.087
6	-0.144	0.087
7	-0.275	0.087
8	-0.029	0.087
9	0.042	0.087
10	-0.174	0.087
11	-0.037	0.087
12	-0.028	0.087
13	0.158	0.087
14	-0.065	0.087
15	0.043	0.087
16	0.05	0.087
17	0.069	0.087
18	-0.105	0.087
19	0.009	0.087
20	0.132	0.087
21	-0.08	0.087
22	-0.063	0.087
23	0.02	0.087
24	-0.07	0.087
25	0.082	0.087
26	0.112	0.087
27	-0.029	0.087
28	-0.058	0.087
29	0.052	0.087
30	-0.021	0.087
31	-0.066	0.087
32	-0.059	0.087
33	0.082	0.087
34	0.104	0.087
35	-0.082	0.087
36	0.036	0.087

ANEXO J

Prueba de Homogeneidad de Varianzas y ANOVA para Serie Original Compra

Prueba de homogeneidad de varianzas para la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre 2014.

	Estadístico de Levene	gl1	gl2	Sig.
Compra	6.014	11	120	0.000

Fuente: BCRP- Elaboración propia.

En la tabla N° 05, se observa que el Sig. = 0.000 < 0.05, por lo tanto, se concluye que las varianzas interanuales no son iguales para la compra del dólar del sistema bancario.

ANOVA para la compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre 2014.

	Suma de cuadrados	Gl	Media cuadrática	F	Sig.
Inter-grupos	8.262	11	0.826		
Intra-grupos	0.726	120	0.006	137.63	0.000
Total	8.989	131			

Fuente: BCRP- Elaboración propia

En la tabla N° 06, se aprecia el ANOVA donde el Sig. = 0.000 < 0.05, por lo tanto, se concluye estadísticamente existe diferencias significativas en por lo menos un par de medias de las muestras de los años de la serie compra del dólar del sistema bancario. En consecuencia, se tiene que realizar transformaciones a la serie original para poder aplicar la metodología de Box y Jenkins.

ANEXO K

Prueba de homogeneidad de varianzas para la serie original - compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre 2014.

PRUEBA DE LEVENE PARA LA HOMOGENEIDAD DE VARIANZA

COMPRA:

HIPOTESIS:

$$H_0 = \sigma_{2004}^2 = \sigma_{2005}^2 = \sigma_{2006}^2 = \dots = \sigma_{2014}^2$$

$$H_1 = \sigma_i^2 \neq \sigma_j^2 \text{ para por lo menos un par de (i,j) años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Estadístico de Levene	gl1	gl2	Sig.
Compra	6.014	10	121	0.000

DECISION Y CONCLUSION: el estadístico de Levene = 6.014 y el p-valor igual a 0.000 es menor que el 0.05, rechazamos la hipótesis nula, es decir las varianzas no son homogéneas para la compra del dólar del sistema bancario.

ANEXO L

ANOVA para la compra del dólar del sistema bancario, registrado por el BCRP, periodo enero 2004 a diciembre 2014.

COMPRA:

HIPOTESIS:

$$H_0 = \mu_{2004} = \mu_{2005} = \mu_{2006} = \dots = \mu_{2014}$$

$$H_1 = \mu_i \neq \mu_j \text{ para por lo menos un par de } (i, j) \text{ años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Inter-grupos	8.262	10	0.826	137.63	0.000
Intra-grupos	0.726	121	0.006		
Total	8.989	131			

DECISION Y CONCLUSION: El p-valor igual a 0.000 siendo menor que el 0.05, entonces se rechaza la hipótesis nula, es decir estadísticamente existe diferencia significativa en por lo menos un par de medias de las muestras de los años de la serie compra del dólar del sistema bancario, por lo tanto, no cumple con uno de los supuestos que las medias sean constantes.

ANEXO M

Prueba de homogeneidad de varianzas para la serie Diferenciada en dos periodos
Ln compra del dólar del sistema bancario, registrados por el BCRP, periodo enero
2004 a diciembre 2014.

PRUEBA DE LEVENNE PARA LA HOMOGENEIDAD DE VARIANZA

COMPRA:

HIPOTESIS:

$$H_0 = \sigma_{2004}^2 = \sigma_{2005}^2 = \sigma_{2006}^2 = \dots = \sigma_{2014}^2$$

$$H_1 = \sigma_i^2 \neq \sigma_j^2 \text{ para por lo menos un par de (i,j) años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Estadístico de Levene	gl1	gl2	Sig.
Segunda diferencia del ln compra	0.782	10	118	0.657

DECISION Y CONCLUSION: el estadístico de Levene = 0.782 y el p-valor igual
a 0.657 es mayor que el 0.05, acepto la hipótesis nula, es decir las varianzas son
homogéneas para compra del dólar del sistema bancario.

ANEXO N

ANOVA para Diferencia en dos periodos del Ln compra del dólar del sistema bancario, registrado por el BCRP, periodo enero 2004 a diciembre 2014

COMPRA:

HIPOTESIS:

$$H_0 = \mu_{2004} = \mu_{2005} = \mu_{2006} = \dots = \mu_{2014}$$

$$H_1 = \mu_i \neq \mu_j \text{ para por lo menos un par de } (i, j) \text{ años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Inter-grupos	8.262	10	0.826	137.63	0.000
Intra-grupos	0.726	121	0.006		
Total	8.989	131			

DECISION Y CONCLUSION: El p-valor igual a 0.538 siendo mayor que el 0.05, entonces se acepta la hipótesis nula, es decir estadísticamente no existe diferencia significativa en por lo menos un par de medias de las muestras de los años de la serie compra del dólar del sistema bancario, por lo tanto cumple con uno de los supuestos que las medias sean constante.

ANEXO O

Prueba de Homogeneidad de Varianzas y ANOVA para Serie Venta

Prueba de homogeneidad de varianzas para la venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre 2014.

	Estadístico de Levene	gl1	gl2	Sig.
Venta	5.206	11	120	0.000

Fuente: BCRP- Elaboración propia.

En la tabla N° 27, se observa el estadístico de levene = 5.206 y su Sig. = 0.000 < 0.05, por lo tanto, se concluye que las varianzas interanuales no son iguales para la venta del dólar del sistema bancario.

ANOVA para la venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre 2014.

	Suma de cuadrados	Gl	Media cuadrática	F	Sig.
Inter- grupos	8.056	11	0.806	132.98	0.000
Intra- grupos	0.733	120	0.006		
Total	8.79	131			

Fuente: BCRP- Elaboración propia.

En la tabla N° 28, se aprecia el ANOVA donde el Sig. = 0.000 < 0.05, por lo tanto, se concluye estadísticamente existe diferencias significativas en por lo menos un par de medias de las muestras de los años de la serie venta del dólar del sistema bancario. En consecuencia, se tiene que realizar transformaciones a la serie original para poder aplicar la metodología de Box y Jenkins.

ANEXO P

Prueba de homogeneidad de varianzas para la serie venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre 2014.

PRUEBA DE LEVENNE PARA LA HOMOGENEIDAD DE VARIANZ

VENTA

HIPOTESIS:

$$H_0 = \sigma_{2004}^2 = \sigma_{2005}^2 = \sigma_{2006}^2 = \dots = \sigma_{2014}^2$$

$$H_1 = \sigma_i^2 \neq \sigma_j^2 \text{ para por lo menos un par de (i,j) años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Estadístico de Levene	gl1	gl2	Sig.
Venta	5.206	10	121	0.000

DECISION Y CONCLUSION: el estadístico de Levene = 5.206 y el p-valor igual a 0.000 es menor que el 0.05, rechazamos la hipótesis nula, es decir las varianzas no son homogéneas para la venta del dólar del sistema bancario.

ANEXO Q

ANOVA para la venta del dólar del sistema bancario, registrado por el BCRP, periodo enero 2004 a diciembre 2014.

VENTA:

HIPOTESIS:

$$H_0 = \mu_{2004} = \mu_{2005} = \mu_{2006} = \dots = \mu_{2014}$$

$$H_1 = \mu_i \neq \mu_j \text{ para por lo menos un par de } (i, j) \text{ años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Inter-grupos	8.262	10	0.826	137.63	0.000
Intra-grupos	0.726	121	0.006		
Total	8.989	131			

DECISION Y CONCLUSION: ∴ El p-valor igual a 0.000 siendo menor que el 0.05, entonces se rechaza la hipótesis nula, es decir estadísticamente existe diferencia significativa en por lo menos un par de medias de las muestras de los años de la serie venta del dólar del sistema bancario, por lo tanto no cumple con uno de los supuestos que las medias sean constantes.

ANEXO R

Prueba de homogeneidad de varianzas para la serie Diferenciada en un periodo

Ln venta del dólar del sistema bancario, registrados por el BCRP, periodo enero

2004 a diciembre 2014

PRUEBA DE LEVENE PARA LA HOMOGENEIDAD DE VARIANZ

VENTA:

HIPOTESIS:

$$H_0 = \sigma_{2004}^2 = \sigma_{2005}^2 = \sigma_{2006}^2 = \dots = \sigma_{2014}^2$$

$$H_1 = \sigma_i^2 \neq \sigma_j^2 \text{ para por lo menos un para de (i,j) años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Estadístico de Levene	gl1	gl2	Sig.
Primera diferencia del Ln venta	1.329	11	119	0.217

DECISION Y CONCLUSION: el estadístico de Levene = 1.329 y el p-valor igual a 0.217 es mayor que el 0.05, acepto la hipótesis nula, es decir las varianzas son homogéneas para venta del dólar del sistema bancario.

ANEXO S

ANOVA para Diferencia en un periodo del Ln venta del dólar del sistema bancario, registrado por el BCRP, periodo enero 2004 a diciembre 2014.

COMPRA:

HIPOTESIS:

$$H_0 = \mu_{2004} = \mu_{2005} = \mu_{2006} = \dots = \mu_{2014}$$

$$H_1 = \mu_i \neq \mu_j \text{ para por lo menos un par de } (i, j) \text{ años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Inter-grupos	8.262	10	0.826	137.63	0.000
Intra-grupos	0.726	121	0.006		
Total	8.989	131			

DECISION Y CONCLUSION: El p-valor igual a 0.962 siendo mayor que el 0.05, entonces se acepta la hipótesis nula, es decir estadísticamente no existe diferencia significativa en por lo menos un par de medias de las muestras de los años de la serie venta del dólar del sistema bancario, por lo tanto cumple con uno de los supuestos que las medias sean constantes.

ANEXO T

Prueba de Normalidad de Kolmogorov-Smirnov

Se probó la normalidad de los errores del modelo ARIMA (2, 2,3), aplicando a la variable de estudio Compra del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

HIPOTESIS

H0: Los errores aleatorios siguen aproximadamente una distribución normal.

H1: Los errores aleatorios no siguen aproximadamente una distribución normal.

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA (Kolmogorov-Smirnov).

		Ruido residual de LN_compra-Modelo_1
N		130
Parámetros normales ^{a,b}	Media	-,0001
	Desviación típica	,01144
	Absoluta	,101
Diferencias más extremas	Positiva	,101
	Negativa	-,087
Z de Kolmogorov-Smirnov		1,153
Sig. asintótica. (bilateral)		,140

a. La distribución de contraste es la Normal.

b. Se han calculado a partir de los datos.

DECISIÓN Y CONCLUSIÓN: El p-valor es igual 0.140 es mayor que el 0.05. Por lo tanto, no se rechaza la hipótesis nula. Se concluye al 95% de confianza de que estadísticamente los errores del modelo ARIMA (2,2, 3) siguen una distribución normal.

ANEXO U

Se probó la normalidad de los errores del modelo ARIMA (3, 1,2), aplicando a la variable de estudio Venta del dólar del sistema bancario, registrados por el BCRP, enero 2004 a diciembre 2014.

HIPOTESIS

H0: Los errores aleatorios siguen aproximadamente una distribución normal.

H1: Los errores aleatorios no siguen aproximadamente una distribución normal.

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA (Kolmogorov-Smirnov).

		Ruido residual de LN_venta-Modelo_1
N		131
Parámetros normales ^{a,b}	Media	,0000
	Desviación típica	,01141
	Absoluta	,076
Diferencias más extremas	Positiva	,076
	Negativa	-,076
Z de Kolmogorov-Smirnov		,875
Sig. asintótica. (bilateral)		,429

a. La distribución de contraste es la Normal.

b. Se han calculado a partir de los datos.

DECISIÓN Y CONCLUSIÓN: El p-valor es igual 0.429 es mayor que el 0.05. Por lo tanto, no se rechaza la hipótesis nula. Se concluye al 95% de confianza de que estadísticamente los errores del modelo ARIMA (3, 1, 2) siguen una distribución normal.

ANEXO V

Prueba de homogeneidad de varianzas para los errores del pronóstico del modelo ARIMA (2, 2, 3) compra del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre 2014.

PRUEBA DE LEVENE PARA LA HOMOGENEIDAD DE VARIANZA

COMPRA:

HIPOTESIS:

$$H_0 = \sigma_{2004}^2 = \sigma_{2005}^2 = \sigma_{2006}^2 = \dots = \sigma_{2014}^2$$

$$H_1 = \sigma_i^2 \neq \sigma_j^2 \text{ para por lo menos un par de (i,j) años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Estadístico de Levene	gl1	gl2	Sig.
Compra	0.962	11	118	0.485

DECISION Y CONCLUSION: el estadístico de Levene = 0.962 y el p-valor igual a 0.485 es mayor que el 0.05, entonces aceptamos la hipótesis nula, es decir las varianzas de los errores de pronóstico son homogéneas para la compra del dólar del sistema bancario.

ANEXO W

Prueba de homogeneidad de varianzas para los errores del pronóstico del modelo ARIMA (3, 1, 2) venta del dólar del sistema bancario, registrados por el BCRP, periodo enero 2004 a diciembre 2014.

PRUEBA DE LEVENE PARA LA HOMOGENEIDAD DE VARIANZA

VENTA

HIPOTESIS:

$$H_0 = \sigma_{2004}^2 = \sigma_{2005}^2 = \sigma_{2006}^2 = \dots = \sigma_{2014}^2$$

$$H_1 = \sigma_i^2 \neq \sigma_j^2 \text{ para por lo menos un par de (i,j) años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Estadístico de Levene	gl1	gl2	Sig.
Venta	0.832	11	119	0.608

DECISION Y CONCLUSION: el estadístico de Levene = 0.832 y el p-valor igual a 0.608 es mayor que el 0.05, entonces aceptamos la hipótesis nula, es decir las varianzas de los errores de pronóstico son homogéneas para la venta del dólar del sistema bancario.

ANEXO X

ANOVA para los errores del pronóstico con el modelo ARIMA (2, 2, 3) compra del dólar del sistema bancario, registrado por el BCRP, periodo enero 2004 a diciembre 2014.

COMPRA:

HIPOTESIS:

$$H_0 = \mu_{2004} = \mu_{2005} = \mu_{2006} = \dots = \mu_{2014}$$

$$H_1 = \mu_i \neq \mu_j \text{ para por lo menos un par de } (i, j) \text{ años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Inter-grupos	8.262	10	0.826	137.63	0.000
Intra-grupos	0.726	121	0.006		
Total	8.989	131			

DECISION Y CONCLUSION: El p-valor igual a 0.505 siendo mayor que el 0.05, entonces con el 95% de confianza se concluye que estadísticamente no existe diferencias significativas entre los promedios de los residuos aplicando el modelo ARIMA (2,2,3) para compra del dólar del sistema bancario, por lo tanto, cumple con uno de los supuestos que las medias sean constantes.

ANEXO Y

ANOVA para los errores del pronóstico con el modelo ARIMA (3, 1, 2) compra del dólar del sistema bancario, registrado por el BCRP, periodo enero 2004 a diciembre 2014.

VENTA:

HIPOTESIS:

$$H_0 = \mu_{2004} = \mu_{2005} = \mu_{2006} = \dots = \mu_{2014}$$

$$H_1 = \mu_i \neq \mu_j \text{ para por lo menos un par de } (i, j) \text{ años}$$

NIVEL DE SIGNIFICANCIA: $\alpha = 0.05$

ESTADISTICA DE PRUEBA:

	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Inter-grupos	8.262	10	0.826	137.63	0.000
Intra-grupos	0.726	121	0.006		
Total	8.989	131			

. DECISION Y CONCLUSION: El p-valor igual a 0.921 siendo mayor que el 0.05, entonces con el 95% de confianza se concluye que estadísticamente no existe diferencias significativas entre los promedios de los residuos aplicando el modelo ARIMA (3,1,2) para venta del dólar del sistema bancario, por lo tanto, cumple con uno de los supuestos que las medias sean constantes

ANEXO Z

PARAMETROS DEL MODELO ARIMA

					Estimación	ET	t	Sig.
LN_compra- Modelo_1	Sin LN_compra transformaci ón	AR	Constante		-0.005	,001	-,066	,948
			Retardo 1		,240	,073	3,302	,001
		Retardo 2		-,919	,067	-13,817	,000	
		Diferencia		2				
	MONTH, period 12	MA	Retardo 1		,790	,110	7,196	,000
			Retardo 2		-,906	,125	-7,259	,000
		Retardo 3		,533	,099	5,377	,000	
		Sin transformaci ón	Numerador	Retardo 0		2.94E-02	,000	,151

					Estimación	ET	t	Sig.	
LN_venta- Modelo_1	LN_venta	transformaci ón	Constante		-,003	,003	-1,104	,272	
				Retardo 1	1,023	,168	6,101	,000	
			Sin	AR	Retardo 2	-1,043	,167	-6,229	,000
				Retardo 3	,415	,084	4,939	,000	
	MONTH, period 12	Sin transformaci ón	Diferencia		1				
				MA	Retardo 1	,675	,172	3,914	,000
				Retardo 2	-,720	,173	-4,164	,000	
			Numerador	Retardo 0	,000	,000	,989	,325	

ANEXO AA

Autocorrelación simple de los residuos al cuadrado del ARIMA (2,2,3) de la compra del sistema bancario en el Perú. Enero 2004 a diciembre 2014.

Autocorrelaciones

Serie: Ruido residual de LN_compra-Modelo_1

Retardo	Autocorrelación	Error estándar ^a	Estadístico de Box-Ljung		
			Valor	gl	Sig. ^b
1	,028	,087	,104	1	,747
2	-,062	,086	,618	2	,734
3	,116	,086	2,437	3	,487
4	-,035	,086	2,600	4	,627
5	-,013	,085	2,623	5	,758
6	-,003	,085	2,625	6	,854
7	-,184	,085	7,373	7	,391
8	-,191	,084	12,504	8	,130
9	-,052	,084	12,888	9	,168
10	-,191	,084	18,111	10	,053
11	-,076	,083	18,945	11	,062
12	-,090	,083	20,129	12	,065
13	-,042	,083	20,394	13	,086
14	,032	,082	20,545	14	,114
15	,062	,082	21,113	15	,133
16	,032	,082	21,265	16	,169
17	,106	,081	22,981	17	,150
18	,006	,081	22,987	18	,191
19	,052	,080	23,400	19	,220
20	,203	,080	29,814	20	,073
21	-,033	,080	29,982	21	,092
22	-,055	,079	30,459	22	,108
23	,088	,079	31,689	23	,107
24	-,061	,079	32,283	24	,120
25	-,093	,078	33,696	25	,115
26	,129	,078	36,459	26	,084
27	-,066	,077	37,177	27	,092
28	-,100	,077	38,849	28	,083
29	,050	,077	39,282	29	,096
30	-,044	,076	39,615	30	,113
31	-,093	,076	41,108	31	,106
32	-,001	,076	41,108	32	,130
33	,002	,075	41,109	33	,157
34	,100	,075	42,891	34	,141
35	-,015	,074	42,930	35	,168
36	-,026	,074	43,058	36	,195

a. El proceso subyacente asumido es independencia (ruido blanco).

b. Se basa en la aproximación de chi-cuadrado asintótica.

ANEXO AB

Autocorrelación parcial de los residuos al cuadrado del ARIMA (2,2,3) de la compra del sistema bancario en el Perú. Enero 2004 a diciembre 2014.

Autocorrelaciones parciales

Serie: Ruido residual de LN_compra-Modelo_1

Retardo	Autocorrelación parcial	Error estándar
1	,028	,088
2	-,063	,088
3	,120	,088
4	-,047	,088
5	,005	,088
6	-,022	,088
7	-,178	,088
8	-,189	,088
9	-,072	,088
10	-,194	,088
11	-,067	,088
12	-,149	,088
13	-,047	,088
14	-,048	,088
15	-,014	,088
16	-,051	,088
17	,010	,088
18	-,128	,088
19	-,038	,088
20	,081	,088
21	-,081	,088
22	-,094	,088
23	,033	,088
24	-,069	,088
25	-,086	,088
26	,110	,088
27	,004	,088
28	-,048	,088
29	,018	,088
30	-,002	,088
31	-,098	,088
32	-,060	,088
33	,008	,088
34	,125	,088
35	-,072	,088
36	,007	,088

Interpretación:

Se observó que todas las probabilidades de las autocorrelaciones simples y parciales fueron mayores que 0.05, lo cual indicó que no existe heterocedasticidad en los residuo del modelo encontrado; verificándose con la prueba del estadístico de levene (ver ANEXO)

ANEXO AC

Autocorrelación simple de los residuos al cuadrado del ARIMA (3,1,2) de la venta del sistema bancario en el Perú. Enero 2004 a diciembre 2014.

Autocorrelaciones

Serie: Ruido residual de LN_venta-Modelo_1

Retardo	Autocorrelación	Error estándar ^a	Estadístico de Box-Ljung		
			Valor	gl	Sig. ^b
1	-,011	,086	,016	1	,899
2	,005	,086	,020	2	,990
3	,066	,086	,605	3	,895
4	-,070	,085	1,281	4	,865
5	,057	,085	1,725	5	,886
6	,067	,085	2,347	6	,885
7	-,143	,084	5,228	7	,632
8	-,102	,084	6,700	8	,569
9	,011	,084	6,718	9	,666
10	-,206	,083	12,842	10	,233
11	-,069	,083	13,539	11	,260
12	-,091	,083	14,739	12	,256
13	,077	,082	15,611	13	,271
14	,011	,082	15,627	14	,337
15	,001	,082	15,628	15	,407
16	-,015	,081	15,660	16	,477
17	,143	,081	18,797	17	,340
18	,018	,081	18,845	18	,401
19	,016	,080	18,883	19	,464
20	,168	,080	23,301	20	,274
21	-,022	,079	23,375	21	,324
22	,000	,079	23,375	22	,381
23	,036	,079	23,579	23	,427
24	-,143	,078	26,907	24	,309
25	-,053	,078	27,365	25	,338
26	,167	,078	31,997	26	,193
27	-,059	,077	32,587	27	,211
28	-,069	,077	33,385	28	,222
29	,043	,077	33,705	29	,250
30	-,082	,076	34,878	30	,247
31	-,005	,076	34,882	31	,288
32	,000	,075	34,882	32	,333
33	-,032	,075	35,070	33	,370
34	,120	,075	37,636	34	,306
35	-,008	,074	37,647	35	,349
36	-,058	,074	38,258	36	,367

a. El proceso subyacente asumido es independencia (ruido blanco).

b. Se basa en la aproximación de chi-cuadrado asintótica.

ANEXO X

Autocorrelación parcial de los residuos al cuadrado del ARIMA (3,1,2) de la venta del sistema bancario en el Perú. Enero 2004 a diciembre 2014.

Autocorrelaciones parciales

Serie: Ruido residual de LN_venta-
Modelo_1

Retardo	Autocorrelación parcial	Error estándar
1	-,011	,087
2	,005	,087
3	,066	,087
4	-,069	,087
5	,055	,087
6	,065	,087
7	-,136	,087
8	-,119	,087
9	,013	,087
10	-,189	,087
11	-,096	,087
12	-,102	,087
13	,135	,087
14	-,012	,087
15	-,008	,087
16	-,010	,087
17	,150	,087
18	-,053	,087
19	-,041	,087
20	,145	,087
21	,008	,087
22	-,091	,087
23	,030	,087
24	-,075	,087
25	-,042	,087
26	,124	,087
27	,069	,087
28	-,049	,087
29	,051	,087
30	-,009	,087
31	-,023	,087
32	-,071	,087
33	-,006	,087
34	,120	,087
35	-,061	,087
36	-,059	,087

Interpretación:

se observó que todas las probabilidades de las autocorrelaciones simples y parciales fueron mayores que 0.05, lo cual indicó que no existe heterocedasticidad en los residuos del modelo encontrado; verificándose con la prueba del estadístico de levene.

APENDICE

Demanda

Se refiere uno a la cantidad de bienes o servicios que se solicitan o se desean en un determinado mercado de una economía a un precio específico.

La demanda que una persona, una familia, una empresa o un consumidor en general tiene de un determinado producto o servicio puede estar influenciada por un gran número de factores que determinarán la cantidad de producto solicitado o demandado o, incluso, si éste tiene demanda o no.

Error medio absoluto de una medida

Corresponde al valor absoluto de la diferencia del valor medio respecto a cada medida.

Error medio absoluto de una serie de medidas

Valor medio aritmético de los errores absolutos de cada medida.

Función de Transferencia

Es la representación equivalente de sistemas de variables de estado empleando la transformada de Laplace.

Exportaciones

Es cualquier bien o servicio enviado fuera del territorio nacional. La exportación es el tráfico legítimo de bienes y/o servicios desde un territorio aduanero hacia otro territorio aduanero.

Flotación Administrada

La flotación administrada es un régimen cambiario en principio dejado al accionar del mercado, pero, en el cual, la autoridad monetaria interviene intensa y sistemáticamente (esta incidencia es más fuerte que en la flotación sucia).

Fluctuaciones

El encargado de la política cambiaria en el Perú es el Banco Central de Reserva (BCRP), ente encargado de definir el sistema cambiario.

Importaciones

Es el transporte legítimo de bienes y servicios nacionales exportados por un país, pretendidos para el uso o consumo interno de otro país. Las importaciones pueden ser cualquier producto o servicio recibido dentro de la frontera de un Estado con propósitos comerciales. Las importaciones son generalmente llevadas a cabo bajo condiciones específicas.

Intercambio comercial

Es la compra-venta de mercancías a un precio conveniente entre las partes considerando (hoy en día) políticas de comercio internacional y relaciones diplomáticas con el resto del mundo, su importancia es estratégica, principalmente dotar al mercado de bienes y servicios para satisfacer necesidades básicas o especulativas en la sociedad de acuerdo a ventajas competitivas y comparativas que pongan en una posición especial a una nación.

Macroeconomía

Es la parte de la teoría económica que se encarga del estudio general de la economía, mediante el análisis de las variables agregadas como el monto total de bienes y servicios producidos, el total de los ingresos, el nivel de empleo, de recursos productivos, la balanza de pagos, el tipo de cambio y el comportamiento general de los precios.

Mercado

Es el contexto en donde tienen lugar los intercambios de productos y servicios. Es decir que en ese contexto es en dónde se llevan a cabo las ofertas, las demandas, las compras y las ventas.

Oferta

Es una fuerza del mercado (la otra es la "demanda") que representa la cantidad de bienes o servicios que individuos, empresas u organizaciones quieren y pueden vender en el mercado a un precio determinado.

Predicción

La mayoría de los pronósticos requeridos para la toma de decisiones se maneja discrecionalmente en forma intuitiva, a menudo sin separar de manera explícita la tarea de elaborar los pronósticos y la toma de decisiones. Esto sucede aún dentro de las grandes organizaciones.

Pronósticos

Predecir, es estimar el futuro utilizando información del presente y del pasado. El conocimiento del futuro nos capacita para planificar, prever o prevenir

Redes Neuronales

Las redes neuronales son métodos de aprendizaje que resultan eficaces para aproximaciones de valores reales. Se trata de un sistema de interconexión de neuronas en una red que colabora para producir un estímulo de salida.

Series de Tiempo

Una serie tiempo es una secuencia de observaciones, medidos en determinados momentos del tiempo, ordenados cronológicamente y, espaciados entre sí de manera uniforme

Sistema Cambiario

Una forma de determinar el tipo de cambio. Perú tiene un sistema cambiario de flotación administrada o sucia, de acuerdo con el cual, el tipo de cambio se establece en el libre mercado con intervención del Banco Central solo para evitar fluctuaciones bruscas.

Swaps

Es un contrato por el cual dos partes se comprometen a intercambiar una serie de cantidades de dinero en fechas futuras. Normalmente los intercambios de dinero futuros están referenciados a tipos de interés, llamándose **IRS** (Interest Rate Swap) aunque de forma más genérica se puede considerar un **swap** cualquier intercambio futuro de bienes o servicios.

Tipo de cambio

El tipo de cambio, es el precio de una divisa respecto a otra. Usualmente es la cantidad de moneda nacional que debe ser entregada a cambio de una unidad de moneda extranjera.